

# 

# 基础编程、实验和案例教程

#### 林子雨 编著

○ **步步引导,循序渐进** 详尽的安装指南为顺利搭建大数据实验环境铺平道路

○ **深入浅出,去粗取精** 丰富的代码实例帮助快速掌握大数据基础编程方法

○ **精心设计,巧妙融合** 五套大数据实验题目促进理论与编程知识的消化和吸收

○ **结合理论,联系实际** 大数据课程综合实验案例精彩呈现大数据分析全流程

清华大学出版社

# 大数据基础编程、实验和案例教程

林子雨 编著

清华大学出版社 北 京

#### 内容简介

本书以大数据分析全流程为主线,介绍了数据采集、数据存储与管理、数据处理与分析、数据可视化等环节典型软件的安装、使用和基础编程方法。本书内容涵盖操作系统(Linux 和 Windows)、开发工具(Eclipse)以及大数据相关技术、软件(Sqoop、Kafka、Flume、Hadoop、HDFS、MapReduce、HBase、Hive、Spark、MySQL、MongoDB、Redis、R、Easel.ly、D3、魔镜、ECharts、Tableau)等。同时,本书还提供了丰富的课程实验和综合案例,以及大量免费的在线教学资源,可以较好地满足高等院校大数据教学实际需求。

本书是《大数据技术原理与应用——概念、存储、处理、分析与应用》的"姊妹篇",可以作为高等院校计算机、信息管理等相关专业的大数据课程辅助教材,用于指导大数据编程实践;也可供相关技术人员参考。

本书封面贴有清华大学出版社防伪标签,无标签者不得销售。版权所有,侵权必究。侵权举报电话: 010-62782989 13701121933

#### 图书在版编目(CIP)数据

大数据基础编程、实验和案例教程/林子雨编著. —北京:清华大学出版社,2017 ISBN 978-7-302-47209-4

I. ①大··· Ⅱ. ①林··· Ⅲ. ①数据处理-教材 Ⅳ. ①TP274

中国版本图书馆 CIP 数据核字(2017)第 125787 号

责任编辑:白立军

封面设计:杨玉兰

责任校对:梁 毅

责任印制:李红英

出版发行:清华大学出版社

网 址: http://www.tup.com.cn, http://www.wqbook.com

地 址:北京清华大学学研大厦 A 座 邮 编:100084

社 总 机: 010-62770175 邮 购: 010-62786544

投稿与读者服务: 010-62776969, c-service@tup. tsinghua. edu. cn

质量反馈: 010-62772015, zhiliang@tup. tsinghua. edu. cn

课件下载: http://www.tup.com.cn,010-62795954

印装者:清华大学印刷厂

经 销:全国新华书店

开 本: 185mm×260mm 印 张: 23.75 字 数: 568 千字

卸 数: 2001∼3500

定 价: 59.00 元

产品编号: 074870-01

# 作者介绍

林子雨(1978-),男,博士,厦门大学计算机科学系助理教授,厦门大学云计算与大数据

研究中心创始成员,厦门大学数据库实验室负责人,中国计算机学会数据库专委会委员,中国计算机学会信息系统专委会委员;于2001年获得福州大学水利水电专业学士学位,2005年获得厦门大学计算机专业硕士学位,2009年获得北京大学计算机专业博士学位;中国高校首个"数字教师"提出者和建设者(http://www.cs.xmu.edu.cn/linziyu),2009年至今,"数字教师"大平台累计向网络免费发布超过500万字高价值的教学和科研资料,累计网络访问量超过500万次。



主要研究方向为数据库、数据仓库、数据挖掘、大数据和云计算,发表期刊和会议学术论文多篇,并作为课题组负责人承担了国家自然科学基金和福建省自然科学基金项目。曾作为志愿者翻译了 Google Spanner、BigTable 和 Architecture of a Database System 等大量英文学术资料,与广大网友分享,深受欢迎;2013 年在厦门大学开设大数据课程,并因在教学领域的突出贡献和学生的认可,成为 2013 年度和 2017 年度厦门大学教学类奖教金获得者。

主讲课程:"大数据处理技术"。

个人主页: http://www.cs.xmu.edu.cn/linziyu。

E-mail: ziyulin@xmu. edu. cn.

数据库实验室网站: http://dblab. xmu. edu. cn。

建设了高校大数据课程公共服务平台(http://dblab.xmu.edu.cn/post/bigdata-teach-ing-platform/),成为全国高校大数据教学知名品牌。平台为教师教学和学生学习大数据课程提供包括教学大纲、讲义 PPT、学习指南、备课指南、实验指南、上机习题、授课视频、技术资料等全方位、一站式免费服务,平台年访问量超过 100 万次;同时提供面向高校的大数据实验平台建设方案和大数据课程师资培训服务。



公



扫一扫访问平台主页

# 前言

大数据带来了信息技术的巨大变革,并深刻影响着社会生产和人民生活的方方面面。大数据专业人才的培养是世界各国新一轮科技较量的基础,高等院校承担着大数据人才培养的重任,需要及时建立大数据课程体系,为社会培养和输送一大批具备大数据专业素养的高级人才,满足社会对大数据人才日益旺盛的需求。

高质量的教材是推进高校大数据课程体系建设的关键支撑。2013年12月,笔者根据自己主讲厦门大学计算机系研究生大数据课程的教学实践,编写了电子书《大数据技术基础》,通过网络免费发布,获得了较好的反响。此后两年多的时间里,笔者继续对大数据技术知识体系进行深入学习和系统梳理,并结合教学实践和大量调研,编著出版了《大数据技术原理与应用》教材,该书第1版于2015年8月出版发行,第2版于2017年1月出版发行。《大数据技术原理与应用》一书侧重于介绍大数据技术的实现原理,编程实践内容较少,该教材定位为入门级大数据教材,以"构建知识体系、阐明基本原理、开展初级实践、了解相关应用"为原则,旨在为读者搭建起通向大数据知识空间的桥梁和纽带,为读者在大数据领域深耕细作奠定基础、指明方向。教材系统论述了大数据的基本概念、大数据处理架构 Hadoop、分布式文件系统 HDFS、分布式数据库 HBase、NoSQL 数据库、云数据库、分布式并行编程模型 MapReduce、大数据处理架构 Spark、流计算、图计算、数据可视化以及大数据在互联网、生物医学和物流等各个领域的应用。

《大数据技术原理与应用》一书出版以后,获得了读者较高的认可,目前已经成为国内多所高校的大数据课程教材。与此同时,笔者在最近两年通过各种形式助力全国高校加快推进大数据课程建设,包括建设全国高校大数据课程公共服务平台、开展全国高校大数据公开课巡讲计划、组织全国高校大数据教学论坛、举办全国高校大数据课程教师培训交流班等。通过这些活动,笔者与全国高校广大大数据课程教师有了更深的接触和交流,也收集到了广大一线教师的核心教学需求。很多高校教师在高度肯定《大数据技术原理与应用》教材的同时,也提出了很多中肯的改进意见和建议,其中,有很多教师指出,应该加强大数据实践环节的训练,提供实验指导和综合案例。

为了更好地满足高校教学实际需求,笔者带领厦门大学数据库实验团队,

开展了大量的探索和实践,并对实践材料进行系统整理,在此基础上编写了本教程。本教程侧重于介绍大数据软件的安装、使用和基础编程方法,并提供大量实验和案例。由于大数据软件都是开源软件,安装过程一般比较复杂,也很耗费时间。为了尽量减少读者搭建大数据实验环境时的障碍,笔者在本书中详细写出了各种大数据软件的详细安装过程,可以确保读者顺利完成大数据实验环境搭建。

本书共 13 章,详细介绍系统和软件的安装、使用以及基础编程方法。第 1 章介绍大数据的关键技术和代表性软件,帮助读者形成对大数据技术及其代表性软件的总体性认识。第 2 章介绍 Linux 系统的安装和使用方法,为后面其他章节的学习奠定基础。第 3 章介绍分布式计算框架 Hadoop 的安装和使用方法。第 4 章介绍分布式文件系统 HDFS 的基础编程方法。第 5 章介绍分布式数据库 HBase 的安装和基础编程方法。第 6 章介绍典型 No-SQL 数据库的安装和使用方法,包括键值数据库 Redis 和文档数据库 MongoDB。第 7 章介绍如何编写基本的 MapReduce 程序。第 8 章介绍基于 Hadoop 的数据仓库 Hive 的安装和使用方法。第 9 章介绍基于内存的分布式计算框架 Spark 的安装和基础编程方法。第 10 章介绍 5 种典型的可视化工具的安装和使用方法,包括 Easel. ly、D3、魔镜、ECharts、Tableau等。第 11 章介绍数据采集工具的安装和使用方法,包括 Flume、Kafka 和 Sqoop。第 12 章介绍一个大数据课程综合实验案例,即网站用户购物行为分析。第 13 章通过 5 个实验让读者加深对知识的理解。

本书面向高校计算机和信息管理等相关专业的学生,可以作为专业必修课或选修课的辅助教材。本书是《大数据技术原理与应用》的"姊妹篇",可以作为《大数据技术原理与应用》的辅助配套教程,两本书组合使用,可以达到更好的学习效果。此外,本书也可以和市场上现有的其他大数据教材配套使用,作为教学辅助用书。

本书由林子雨执笔。在撰写过程中,厦门大学计算机科学系硕士研究生谢荣东、罗道文、邓少军、阮榕城、薛倩、魏亮、曾冠华等做了大量辅助性工作,在此,向这些同学的辛勤工作表示衷心的感谢。

本书的官方网站是 http://dblab. xmu. edu. cn/post/bigdatapractice/,免费提供了全部配套资源的在线浏览和下载,并接受错误反馈和发布勘误信息。同时,在学习大数据课程的过程中,欢迎读者访问厦门大学数据库实验室建设的国内高校首个大数据课程公共服务平台(http://dblab. xmu. edu. cn/post/bigdata-teaching-platform/),该平台为教师教学和学生学习大数据课程提供讲义 PPT、学习指南、备课指南、上机习题、技术资料、授课视频等全方位、一站式免费服务。

本书在撰写过程中,参考了大量网络资料,对大数据技术及其典型软件进行了系统梳理,有选择地把一些重要知识纳入本书。由于笔者能力有限,本书难免存在不足之处,望广大读者不吝赐教。

林子雨

2017年2月于厦门大学计算机科学系数据库实验室

# ] 录

## 第1章 大数据技术概述 /1

- 1.1 大数据时代 /1
- 1.2 大数据关键技术 /2
- 1.3 大数据软件 /3
  - 1.3.1 Hadoop /4
  - 1.3.2 Spark /5
  - 1.3.3 NoSQL 数据库 /5
  - 1.3.4 数据可视化 /6
- 1.4 内容安排 /7
- 1.5 在线资源 /8
  - 1.5.1 在线资源一览表 /9
  - 1.5.2 下载专区 /9
  - 1.5.3 在线视频 /10
  - 1.5.4 拓展阅读 /11
  - 1.5.5 大数据课程公共服务平台 /11
- 1.6 本章小结 /12

#### 第2章 Linux 系统的安装和使用 /13

- 2.1 Linux 系统简介 /13
- 2.2 Linux 系统安装 /13
  - 2.2.1 下载安装文件 /14
  - 2.2.2 Linux 系统的安装方式 /14
  - 2.2.3 安装 Linux 虚拟机 /15
  - 2.2.4 生成 Linux 虚拟机镜像文件 /36
- 2.3 Linux 系统及相关软件的基本使用方法 /38
  - 2. 3. 1 Shell /38
  - 2.3.2 root 用户 /38
  - 2.3.3 创建普通用户 /38

- 2.3.4 sudo 命令 /39
- 2.3.5 常用的 Linux 系统命令 /40
- 2.3.6 文件解压缩 /40
- 2.3.7 常用的目录 /41
- 2.3.8 目录的权限 /41
- 2.3.9 更新 APT /41
- 2.3.10 切换中英文输入法 /43
- 2.3.11 vim 编辑器的使用方法 /43
- 2.3.12 在 Windows 系统中使用 SSH 方式登录 Linux 系统 /44
- 2.3.13 在 Linux 中安装 Eclipse /48
- 2.3.14 其他使用技巧 /49
- 2.4 关于本书内容的一些约定 /49
- 2.5 本章小结 /50

#### **第 3 章 Hadoop** 的安装和使用 /51

- 3.1 Hadoop 简介 /51
- 3.2 安装 Hadoop 前的准备工作 /52
  - 3. 2. 1 创建 hadoop 用户 /52
  - 3.2.2 更新 APT /52
  - 3.2.3 安装 SSH /52
  - 3.2.4 安装 Java 环境 /53
- 3.3 安装 Hadoop /55
  - 3.3.1 下载安装文件 /55
  - 3.3.2 单机模式配置 /56
  - 3.3.3 伪分布式模式配置 /57
  - 3.3.4 分布式模式配置 /66
  - 3.3.5 使用 Docker 搭建 Hadoop 分布式集群 /75
- 3.4 本章小结 /87

#### 第 4 章 HDFS 操作方法和基础编程 /88

- 4.1 HDFS 操作常用 Shell 命令 /88
  - 4.1.1 查看命令使用方法 /88
  - 4.1.2 HDFS 目录操作 /90
- 4.2 利用 HDFS 的 Web 管理界面 /92
- 4.3 HDFS 编程实践 /92
  - 4.3.1 在 Eclipse 中创建项目 /93
  - 4.3.2 为项目添加需要用到的 JAR 包 /94
  - 4.3.3 编写 Java 应用程序 /96
  - 4.3.4 编译运行程序 /98

#### 4.3.5 应用程序的部署 /100

#### 4.4 本章小结 /102

#### 第5章 HBase 的安装和基础编程 /103

- 5.1 安装 HBase /103
  - 5.1.1 下载安装文件 /103
  - 5.1.2 配置环境变量 /104
  - 5.1.3 添加用户权限 /104
  - 5.1.4 查看 HBase 版本信息 /104
- 5.2 HBase 的配置 /105
  - 5.2.1 单机模式配置 /105
  - 5.2.2 伪分布式配置 /107
- 5.3 HBase 常用 Shell 命令 /109
  - 5.3.1 在 HBase 中创建表 /109
  - 5.3.2 添加数据 /110
  - 5.3.3 查看数据 /110
  - 5.3.4 删除数据 /111
  - 5.3.5 删除表 /112
  - 5.3.6 查询历史数据 /112
  - 5.3.7 退出 HBase 数据库 /112
- 5.4 HBase 编程实践 /113
  - 5.4.1 在 Eclipse 中创建项目 /113
  - 5.4.2 为项目添加需要用到的 JAR 包 /116
  - 5.4.3 编写 Java 应用程序 /117
  - 5.4.4 编译运行程序 /123
  - 5.4.5 应用程序的部署 /124
- 5.5 本章小结 /124

#### 第 6 章 典型 NoSQL 数据库的安装和使用 /125

- 6.1 Redis 安装和使用 /125
  - 6.1.1 Redis 简介 /125
  - 6.1.2 安装 Redis /125
  - 6.1.3 Redis 实例演示 /127
- 6.2 MongoDB 的安装和使用 /128
  - 6.2.1 MongDB 简介 /129
  - 6.2.2 安装 MongoDB /129
  - 6.2.3 使用 Shell 命令操作 MongoDB /130
  - 6.2.4 Java API 编程实例 /136
- 6.3 本章小结 /139

#### 第7章 MapReduce 基础编程 /140

- 7.1 词频统计任务要求 /140
- 7.2 MapReduce 程序编写方法 /141
  - 7.2.1 编写 Map 处理逻辑 /141
  - 7.2.2 编写 Reduce 处理逻辑 /141
  - 7.2.3 编写 main 方法 /142
  - 7.2.4 完整的词频统计程序 /143
- 7.3 编译打包程序 /144
  - 7.3.1 使用命令行编译打包词频统计程序 /145
  - 7.3.2 使用 Eclipse 编译运行词频统计程序 /145
- 7.4 运行程序 /154
- 7.5 本章小结 /156

#### 第8章 数据仓库 Hive 的安装和使用 /157

- 8.1 Hive 的安装 /157
  - 8.1.1 下载安装文件 /157
  - 8.1.2 配置环境变量 /158
  - 8.1.3 修改配置文件 /158
  - 8.1.4 安装并配置 MySQL /159
- 8.2 Hive 的数据类型 /161
- 8.3 Hive 基本操作 /162
  - 8.3.1 创建数据库、表、视图 /162
  - 8.3.2 删除数据库、表、视图 /163
  - 8.3.3 修改数据库、表、视图 /164
  - 8.3.4 查看数据库、表、视图 /165
  - 8.3.5 描述数据库、表、视图 /165
  - 8.3.6 向表中装载数据 /166
  - 8.3.7 查询表中数据 /166
  - 8.3.8 向表中插入数据或从表中导出数据 /166
- 8.4 Hive 应用实例: WordCount /167
- 8.5 Hive 编程的优势 /167
- 8.6 本章小结 /168

#### 第9章 Spark 的安装和基础编程 /169

- 9.1 基础环境 /169
- 9.2 安装 Spark /169
  - 9.2.1 下载安装文件 /169
  - 9.2.2 配置相关文件 /170
- 9.3 使用 Spark Shell 编写代码 /171

- 9.3.1 启动 Spark Shell /171
- 9.3.2 读取文件 /172
- 9.3.3 编写词频统计程序 /174
- 9.4 编写 Spark 独立应用程序 /174
  - 9.4.1 用 Scala 语言编写 Spark 独立应用程序 /175
  - 9.4.2 用 Java 语言编写 Spark 独立应用程序 /178
- 9.5 本章小结 /182

#### 第10章 典型的可视化工具的使用方法 /183

- 10.1 Easel. ly 信息图制作方法 /183
  - 10.1.1 信息图 /183
  - 10.1.2 信息图制作基本步骤 /183
- 10.2 D3 可视化库的使用方法 /186
  - 10.2.1 D3 可视化库的安装 /187
  - 10.2.2 基本操作 /187
- 10.3 可视化工具 Tableau 使用方法 /194
  - 10.3.1 安装 Tableau /195
  - 10.3.2 界面功能介绍 /195
  - 10.3.3 Tableau 简单操作 /197
- 10.4 使用"魔镜"制作图表 /202
  - 10.4.1 "魔镜"简介 /202
  - 10.4.2 简单制作实例 /202
- 10.5 使用 ECharts 制作图表 /206
  - 10.5.1 ECharts 简介 /206
  - 10.5.2 ECharts 图表制作方法 /206
  - 10.5.3 两个实例 /210
- 10.6 本章小结 /217

#### 第11章 数据采集工具的安装和使用 /218

- 11.1 Flume /218
  - 11.1.1 安装 Flume /218
  - 11.1.2 两个实例 /220
- 11.2 Kafka /225
  - 11.2.1 Kafka 相关概念 /225
  - 11. 2. 2 安装 Kafka /225
  - 11.2.3 一个实例 /225
- 11.3 Sqoop /227
  - 11.3.1 下载安装文件 /227
  - 11.3.2 修改配置文件 /228

- 11.3.3 配置环境变量 /228
- 11.3.4 添加 MySQL 驱动程序 /228
- 11.3.5 测试与 MySQL 的连接 /229
- 11.4 实例: 编写 Spark 程序使用 Kafka 数据源 /230
  - 11.4.1 Kafka 准备工作 /230
  - 11.4.2 Spark 准备工作 /232
  - 11.4.3 编写 Spark 程序使用 Kafka 数据源 /234
- 11.5 本章小结 /239

#### 第12章 大数据课程综合实验案例 /241

- 12.1 案例简介 /241
  - 12.1.1 案例目的 /241
  - 12.1.2 适用对象 /241
  - 12.1.3 时间安排 /241
  - 12.1.4 预备知识 /241
  - 12.1.5 硬件要求 /242
  - 12.1.6 软件工具 /242
  - 12.1.7 数据集 /242
  - 12.1.8 案例任务 /242
- 12.2 实验环境搭建 /243
- 12.3 实验步骤概述 /244
- 12.4 本地数据集上传到数据仓库 Hive /245
  - 12.4.1 实验数据集的下载 /245
  - 12.4.2 数据集的预处理 /246
  - 12.4.3 导入数据库 /249
- 12.5 Hive 数据分析 /253
  - 12.5.1 简单查询分析 /253
  - 12.5.2 查询条数统计分析 /255
  - 12.5.3 关键字条件查询分析 /256
  - 12.5.4 根据用户行为分析 /258
  - 12.5.5 用户实时查询分析 /259
- 12.6 Hive、MySQL、HBase 数据互导 /260
  - 12.6.1 Hive 预操作 /260
  - 12.6.2 使用 Sqoop 将数据从 Hive 导入 MySQL /261
  - 12.6.3 使用 Sqoop 将数据从 MySQL 导入 HBase /265
  - 12.6.4 使用 HBase Java API 把数据从本地导入到 HBase 中 /269
- 12.7 利用 R 进行数据可视化分析 /275
  - 12.7.1 安装 R /275
  - 12.7.2 安装依赖库 /277

#### 12.7.3 可视化分析 /278

#### 12.8 本章小结 /283

#### 第13章 实验 /283

- 13.1 实验一: 熟悉常用的 Linux 操作和 Hadoop 操作 /284
  - 13.1.1 实验目的 /284
  - 13.1.2 实验平台 /284
  - 13.1.3 实验步骤 /284
  - 13.1.4 实验报告 /286
- 13.2 实验二: 熟悉常用的 HDFS 操作 /286
  - 13.2.1 实验目的 /286
  - 13.2.2 实验平台 /286
  - 13.2.3 实验步骤 /287
  - 13.2.4 实验报告 /287
- 13.3 实验三: 熟悉常用的 HBase 操作 /288
  - 13.3.1 实验目的 /288
  - 13.3.2 实验平台 /288
  - 13.3.3 实验步骤 /288
  - 13.3.4 实验报告 /290
- 13.4 实验四: NoSQL 和关系数据库的操作比较 /290
  - 13.4.1 实验目的 /290
  - 13.4.2 实验平台 /290
  - 13.4.3 实验步骤 /290
  - 13.4.4 实验报告 /293
- 13.5 实验五: MapReduce 初级编程实践 /294
  - 13.5.1 实验目的 /294
  - 13.5.2 实验平台 /294
  - 13.5.3 实验步骤 /294
  - 13.5.4 实验报告 /297

#### 附录 A 大数据课程实验答案 /298

- A.1 实验一: 熟悉常用的 Linux 操作和 Hadoop 操作 /298
  - A.1.1 实验目的 /298
  - A.1.2 实验平台 /298
  - A.1.3 实验步骤 /298
- A. 2 实验二: 熟悉常用的 HDFS 操作 /303
  - A.2.1 实验目的 /303
  - A.2.2 实验平台 /303
  - A.2.3 实验步骤 /303

- A. 3 实验三: 熟悉常用的 HBase 操作 /323
  - A.3.1 实验目的 /323
  - A.3.2 实验平台 /323
  - A.3.3 实验步骤 /323
- A.4 实验四: NoSQL 和关系数据库的操作比较 /331
  - A.4.1 实验目的 /331
  - A.4.2 实验平台 /331
  - A.4.3 实验步骤 /332
- A.5 实验五: MapReduce 初级编程实践 /349
  - A.5.1 实验目的 /349
  - A.5.2 实验平台 /349
  - A.5.3 实验步骤 /350

#### 附录 B Linux 系统中的 MySQL 安装及常用操作 /360

- B.1 安装 MySQL /360
- B. 2 MySQL 常用操作 /363

参考文献 /367

# 第1章

# 大数据技术概述

大数据的时代已经到来,大数据作为继云计算、物联网之后 IT 行业又一颠覆性的技术,备受关注。大数据无处不在,包括金融、汽车、零售、餐饮、电信、能源、政务、医疗、体育、娱乐等在内的社会各行各业,都融入了大数据之中,大数据对人类的社会生产和生活必将产生重大而深远的影响。

本章首先介绍大数据关键技术和各类典型的大数据软件,帮助读者形成对大数据技术 及其代表性软件的总体性认识;然后,给出本书的整体内容安排,帮助读者快速找到相关技术所对应的章节;最后,详细给出与本书配套的在线资源,帮助读者更好、更深入地学习理解相关大数据技术知识。

## 1.1 大数据时代

人类全面进入信息化社会以后,数据以自然方式增长,其产生不以人的意志为转移。从 1986 年开始到 2016 年的 30 年时间里,全球数据的数量增长了 100 多倍,今后的数据量增长速度将更快,我们正生活在一个"数据爆炸"的大数据时代。今天,世界上只有大约 25% 的设备是联网的,大约 80%的上网设备是计算机和手机,而在不远的将来,随着物联网的发展和大规模普及,汽车、电视、家用电器、生产机器等各种设备也将联入互联网,各种传感器和摄像头将遍布人们工作和生活的各个角落,这些设备每时每刻都在自动产生大量数据。可以说,人类社会正经历第二次数据爆炸(如果把印刷在纸上的文字和图片也看作数据,那么,人类历史上第一次数据爆炸发生在造纸术和印刷术发明的时期)。各种数据产生速度之快,产生数量之大,已经远远超出传统技术可以处理的范围,"数据爆炸"成为大数据时代的鲜明特征。

在数据爆炸的今天,人类一方面对知识充满渴求,另一方面为数据的复杂特征所困惑。数据爆炸对科学研究提出了更高的要求,需要人类设计出更加灵活高效的数据存储、处理和分析工具,来应对大数据时代的挑战。由此,必将带来云计算、数据仓库、数据挖掘等技术和应用的提升或者根本性变革。在存储效率(存储技术)领域,需要实现低成本的大规模分布式存储;在网络效率(网络技术)方面,需要实现及时响应的用户体验;在数据中心方面,需要开发更加绿色节能的新一代数据中心,在有效面对大数据处理需求的同时,实现最大化资源利用率、最小化系统能耗的目标。面对数据爆炸的大数据时代,我们人类不再从容!

## 1.2 大数据关键技术

大数据的基本处理流程,主要包括数据采集、存储管理、处理分析、结果呈现等环节。因此,从数据分析全流程的角度,大数据技术主要包括数据采集与预处理、数据存储和管理、数据处理与分析、数据可视化、数据安全和隐私保护等几个层面的内容(具体如表 1-1 所示)。其中,数据可视化有时也被视为数据分析的一种,即可视化分析,因此,数据可视化也可被归入"数据处理与分析"这一大类。

技术层面	功能
数据采集与预处理	利用 ETL(Extraction-Transformation-Loading)工具将分布的、异构数据源中的数据,如关系数据、平面数据文件等,抽取到临时中间层后进行清洗、转换、集成,最后加载到数据仓库或数据集市中,成为联机分析处理、数据挖掘的基础;也可以利用日志采集工具(如 Flume、Kafka 等)把实时采集的数据作为流计算系统的输入,进行实时处理分析
数据存储和 管理	利用分布式文件系统、数据仓库、关系数据库、NoSQL数据库、云数据库等,实现对结构化、半结构化和非结构化海量数据的存储和管理
数据处理与 分析	利用分布式并行编程模型和计算框架,结合机器学习和数据挖掘算法,实现对海量数据的处理和分析
数据可视化	对分析结果进行可视化呈现,帮助人们更好地理解数据、分析数据
数据安全和 隐私保护	在从大数据中挖掘潜在的巨大商业价值和学术价值的同时,构建隐私数据保护体系和数据安全体系,有效保护个人隐私和数据安全

表 1-1 大数据技术的不同层面及其功能

需要指出的是,大数据技术是许多技术的集合体,这些技术也并非全部都是新生事物,诸如关系数据库、数据仓库、数据采集、ETL、OLAP(On-Line Analytical Processing)、数据挖掘、数据隐私和安全、数据可视化等已经发展多年的技术,在大数据时代得到不断补充、完善、提高后又有了新的升华,也可以视为大数据技术的一个组成部分。对于这些技术,除了数据可视化技术以外,我们将不再介绍,本书重点阐述近些年新发展起来的大数据核心技术及其代表性软件使用方法,包括分布式并行编程、分布式文件系统、分布式数据库、NoSQL数据库、日志采集工具等。

此外,大数据技术及其代表性软件种类繁多,不同的技术都有其适用和不适用的场景。 总体而言,不同的企业应用场景,都对应着不同的大数据计算模式,根据不同的大数据计算 模式,可以选择相应的大数据计算产品,具体如表 1-2 所示。

大数据计算模式	解 决 问 题	代表产品
批处理计算	针对大规模数据的批量处理	MapReduce、Spark 等
流计算	针对流数据的实时计算	Storm、S4、Flume、Streams、Puma、DStream、 Super Mario、银河流数据处理平台等

表 1-2 大数据计算模式及其代表产品

1.+	_	-
438	=	=
	1	v

大数据计算模式	解决问题	代 表 产 品
图计算	针对大规模图结构数据的处理	Pregel、GraphX、Giraph、PowerGraph、Hama、 GoldenOrb 等
查询分析计算	大规模数据的存储管理和查询分析	Dremel、Hive、Cassandra、Impala 等

批处理计算主要解决针对大规模数据的批量处理,也是人们日常数据分析工作中非常常见的一类数据处理需求。例如,爬虫程序把大量网页抓取过来存储到数据库中以后,可以使用 MapReduce 对这些网页数据进行批量处理,生成索引,加快搜索引擎的查询速度。

流计算主要是实时处理来自不同数据源的、连续到达的流数据,经过实时分析处理,给出有价值的分析结果。例如,用户在访问淘宝网等电子商务网站时,用户在网页中的每次点击的相关信息(比如选取了什么商品)都会像水流一样实时传播到大数据分析平台,平台采用流计算技术对这些数据进行实时处理分析,构建用户"画像",为其推荐可能感兴趣的其他相关商品。

在大数据时代,许多大数据都是以大规模图或网络的形式呈现,如社交网络、传染病传播途径、交通事故对路网的影响等,此外,许多非图结构的大数据,也常常会被转换为图模型后再进行处理分析。图计算软件是专门针对图结构数据开发的,在处理大规模图结构数据时可以获得很好的性能。

查询分析计算也是一种在企业中常见的应用场景,主要是面向大规模数据的存储管理和查询分析,用户一般只需要输入查询语句(如 SQL),就可以快速得到相关的查询结果。

流计算软件(Storm、S4等)和图计算软件(Pregel、Hama等)学习门槛稍高,一般适合作为高级教程内容,本书作为入门级教程,没有涉及流计算和图计算的内容。感兴趣的读者,可以访问本书官网,学习《大数据技术原理与应用》在线视频的内容,了解图计算和流计算的技术原理和相关软件的使用方法。

# 1.3 大数据软件

本书涉及的大数据软件涵盖数据采集、数据存储与管理、数据处理与分析、数据可视化等环节,每个环节所采用的相关软件如表 1-3 所示。

大数据技术大数据软件数据采集Flume、Kafka、Sqoop数据存储与管理HDFS、HBase、Redis、MongoDB数据处理与分析MapReduce、Spark、Hive数据可视化Easel. ly、D3、Tableau、魔镜、ECharts

表 1-3 本书所涉及的大数据软件

针对表 1-3 中的每一款大数据软件,本书都会给出详细的安装和使用方法介绍,并讲解如何开展基础编程实践。

#### 1.3.1 Hadoop

Hadoop 是 Apache 软件基金会旗下的一个开源分布式计算平台,为用户提供了系统底层细节透明的分布式计算架构。Hadoop 是基于 Java 语言开发的,具有很好的跨平台特性,并且可以部署在廉价的计算机集群中。Hadoop 的核心是分布式文件系统 HDFS(Hadoop Distributed File System)和 MapReduce。借助 Hadoop,程序员可以轻松地编写分布式并行程序,将其运行在廉价的计算机集群上,完成海量数据的存储与计算。经过多年的发展,Hadoop 生态系统不断完善和成熟,目前已经包含多个子项目(见图 1-1)。除了核心的HDFS和 MapReduce 以外,Hadoop 生态系统还包括 YARN、Zookeeper、HBase、Hive、Pig、Mahout、Sqoop、Flume、Ambari等功能组件。

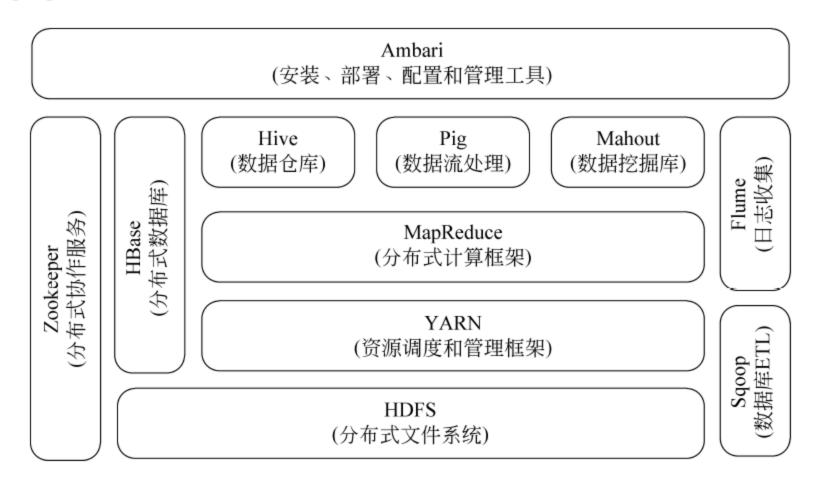


图 1-1 Hadoop 生态系统

本书将详细介绍 HDFS、MapReduce、HBase、Hive、Flume、Sqoop 等组件的安装和使用方法,因此,这里简要介绍一下这些组件的功能,要了解 Hadoop 的更多细节内容,可以访问本书官网,学习《大数据技术原理与应用》在线视频的内容。

- (1) HDFS: Hadoop 分布式文件系统 HDFS 是针对谷歌分布式文件系统 GFS(Google File System)的开源实现,它是 Hadoop 两大核心组成部分之一,提供了在廉价服务器集群中进行大规模分布式文件存储的能力。HDFS 具有很好的容错能力,并且兼容廉价的硬件设备,因此,可以以较低的成本利用现有机器实现大流量和大数据量的读写。
- (2) MapReduce: 是一种分布式并行编程模型,用于大规模数据集(大于 1TB)的并行运算,它将复杂的、运行于大规模集群上的并行计算过程高度抽象为两个函数——Map 和 Reduce。 MapReduce 极大方便了分布式编程工作,编程人员在不会分布式并行编程的情况下,也可以很容易将自己的程序运行在分布式系统上,完成海量数据集的计算。
- (3) HBase: 是针对谷歌 BigTable 的开源实现,是一个高可靠、高性能、面向列、可伸缩的分布式数据库,主要用来存储非结构化和半结构化的松散数据。HBase 可以支持超大规模数据存储,它可以通过水平扩展的方式,利用廉价计算机集群处理由超过 10 亿行数据和数百万列元素组成的数据表。

- (4) Hive: 是一个基于 Hadoop 的数据仓库工具,可以用于对存储在 Hadoop 文件中的数据集进行数据整理、特殊查询和分析处理。 Hive 的学习门槛比较低,因为它提供了类似于关系数据库 SQL 语言的查询语言——HiveQL,可以通过 HiveQL 语句快速实现简单的 MapReduce 统计, Hive 自身可以自动将 HiveQL 语句快速转换成 MapReduce 任务进行运行,而不必开发专门的 MapReduce 应用程序,因而十分适合数据仓库的统计分析。
- (5) Flume: 是 Cloudera 公司开发的一个高可用的、高可靠的、分布式的海量日志采集、聚合和传输系统。Flume 支持在日志系统中定制各类数据发送方,用于收集数据;同时,Flume 提供对数据进行简单处理,并写到各种数据接收方的能力。
- (6) Sqoop: 是 SQL-to-Hadoop 的缩写,主要用来在 Hadoop 和关系数据库之间交换数据,可以改进数据的互操作性。通过 Sqoop,可以方便地将数据从 MySQL、Oracle、PostgreSQL等关系数据库中导入 Hadoop(如导入到 HDFS、HBase 或 Hive 中),或者将数据从 Hadoop 导出到关系数据库,使得传统关系数据库和 Hadoop 之间的数据迁移变得非常方便。

#### 1. 3. 2 Spark

Spark 最初诞生于美国加州大学伯克利分校的 AMP 实验室,是一个可应用于大规模数据处理的快速、通用引擎,如今是 Apache 软件基金会下的顶级开源项目之一。Spark 最初的设计目标是使数据分析更快——不仅运行速度快,也要能快速、容易地编写程序。为了使程序运行更快,Spark 提供了内存计算,减少了迭代计算时的 I/O 开销;而为了使编写程序更容易,Spark 使用简练、优雅的 Scala 语言编写,基于 Scala 提供了交互式的编程体验。虽然 Hadoop 在过去很长一段时间内成为大数据的代名词,但是 MapReduce 分布式计算模型仍存在诸多缺陷,而 Spark 不仅具备了 Hadoop MapReduce 的优点,而且解决了 Hadoop MapReduce 的缺陷。Spark 正以其结构一体化、功能多元化的优势逐渐成为当今大数据领域最热门的大数据计算平台。

Spark 的设计遵循"一个软件栈满足不同应用场景"的理念,逐渐形成了一套完整的生态系统,既能够提供内存计算框架,也可以支持 SQL 即席查询(Spark SQL)、流式计算(Spark Streaming)、机器学习(MLlib)和图计算(GraphX)等。Spark 可以部署在资源管理器 YARN 之上,提供一站式的大数据解决方案。因此,Spark 所提供的生态系统同时支持批处理、交互式查询和流数据处理。

现在,Spark 生态系统已经成为伯克利数据分析软件栈 BDAS(Berkeley Data Analytics Stack)的重要组成部分。BDAS 的架构如图 1-2 所示,从中可以看出,Spark 专注于数据的处理分析,而数据的存储还是要借助于 Hadoop 分布式文件系统 HDFS、Amazon S3 等来实现的。因此,Spark 生态系统可以很好地实现与 Hadoop 生态系统的兼容,使得现有Hadoop 应用程序可以非常容易地迁移到 Spark 系统中。

#### 1.3.3 NoSQL 数据库

NoSQL数据库是一种不同于关系数据库的数据库管理系统,是对一大类非关系型数据库的统称,它所采用的数据模型并非传统关系数据库的关系模型,而是类似键值、列族、文档等非关系模型。NoSQL数据库没有固定的表结构,通常也不存在连接操作,也没有严格遵

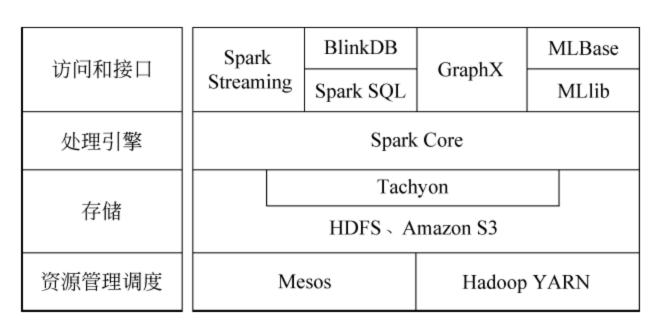


图 1-2 BDAS 架构

守 ACID 约束,因此,与关系数据库相比,NoSQL 具有灵活的水平可扩展性,可以支持海量数据存储。此外,NoSQL 数据库支持 MapReduce 风格的编程,可以较好地应用于大数据时代的各种数据管理。NoSQL 数据库的出现,一方面弥补了关系数据库在当前商业应用中存在的各种缺陷,另一方面也撼动了关系数据库的传统垄断地位。

NoSQL 数据库虽然数量众多,但是,归结起来,典型的 NoSQL 数据库通常包括键值数据库、列族数据库、文档数据库和图数据库。本书将介绍两种流行的 NoSQL 数据库产品的安装和使用方法,即键值数据库 Redis 和文档数据库 MongoDB。

键值数据库(Key-Value Database)会使用一个哈希表,这个表中有一个特定的 Key 和一个指针指向特定的 Value。Key 可以用来定位 Value,即存储和检索具体的 Value。Value 对数据库而言是透明不可见的,不能对 Value 进行索引和查询,只能通过 Key 进行查询。Value 可以用来存储任意类型的数据,包括整型、字符型、数组、对象等。在存在大量写操作的情况下,键值数据库可以比关系数据库取得明显更好的性能。

在文档数据库中,文档是数据库的最小单位。虽然每一种文档数据库的部署都有所不同,但是,大都假定文档以某种标准化格式封装并对数据进行加密,同时用多种格式进行解码,包括 XML、YAML、JSON 和 BSON 等,或者也可以使用二进制格式(如 PDF、微软Office 文档等)。文档数据库通过键来定位一个文档,因此可以看成键值数据库的一个衍生品,而且前者比后者具有更高的查询效率。对于那些可以把输入数据表示成文档的应用而言,文档数据库是非常合适的。

#### 1.3.4 数据可视化

数据可视化是指将大型数据集中的数据以图形图像形式表示,并利用数据分析和开发工具发现其中未知信息的处理过程。数据可视化技术的基本思想是将数据库中每一个数据项作为单个图元素表示,大量的数据集构成数据图像,同时将数据的各个属性值以多维数据的形式表示,可以从不同的维度观察数据,从而对数据进行更深入的观察和分析。虽然可视化在数据分析领域并非最具技术挑战性的部分,但是,它是整个数据分析流程中至关重要的一个环节,毕竟数据分析是为人服务的,分析结果只有能够让用户轻松理解,才能更好地指导生产实践,真正体现数据分析的价值。

本书将介绍 Easel. ly、D3、Tableau、魔镜、ECharts、R 等可视化工具的安装和使用方法。

## 1.4 内容安排

本书以大数据分析全流程为主线(见图 1-3),介绍了数据采集、数据存储与管理、数据 处理与分析、数据可视化等环节典型软件的安装、使用和基础编程方法。

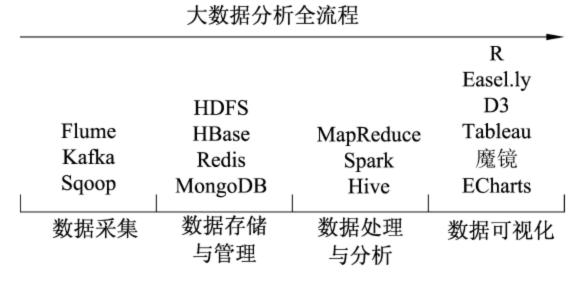


图 1-3 本书中涉及的相关大数据软件

本书涵盖了操作系统(Linux 和 Windows)、开发工具(Eclipse)、大数据相关软件(Sqoop、Kafka、Flume、Hadoop(HDFS、MapReduce)、HBase、Hive、Spark、MySQL、MongoDB、Redis、R、Easel.ly、D3、魔镜、ECharts、Tableau)。其中,数据仓库 Hive 既可以作为数据存储和管理工具,也可以作为数据分析工具。在本书中,这些系统和软件之间的相互关系如图 1-4 所示,需要注意的是,该图仅反映这些软件在本书中的实际关系。

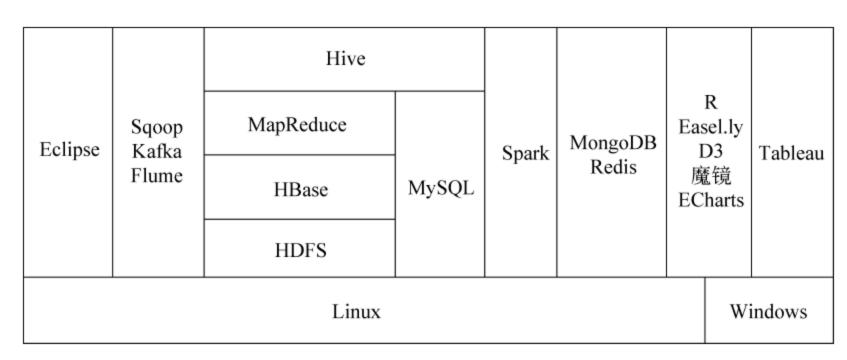


图 1-4 本书中大数据软件之间的相互关系

对于本书中相关系统和软件的相互关系,这里简要说明如下。

- (1) 在操作系统层面,采用 Linux 和 Windows 系统。
- (2) 除了 Tableau 必须在 Windows 系统下使用(Tableau 目前不支持 Linux),其他所有软件都是在 Linux 系统下安装和使用。
- (3) 虽然本书中很多软件都是在 Linux 系统下安装和使用,但是,其中一些软件也可以在 Windows 系统下安装和使用,例如 MySQL、Redis、MongoDB、Eclipse、R、Easel. ly、D3、 魔镜、ECharts 等; Hadoop 和 Spark 通常都是运行在 Linux 系统下。
- (4) 在本书中, HBase 借助于 HDFS 作为底层存储,可以编写 MapReduce 程序对 HDFS 和 HBase 中的数据进行处理和分析; Hive 采用 MySQL 进行 Hive 元数据的存储, Hive 会把 SQL 查询语句自动转换成 MapReduce 任务来执行; Sqoop 用来在 MySQL、

HBase、Hive 之间进行数据相互导入导出;Flume 和 Kafka 采集到的数据会被提交给 Spark 进行处理。

表 1-4 给出了相关大数据软件在本书中的章节安排,可以帮助读者快速找到相关技术 所对应的章节。

软 件	功能	所在章节
Linux	操作系统	第2章
Eclipse	开发工具	第2章
Flume	日志采集工具	第 11 章
Kafka	日志采集工具	第 11 章
Sqoop	数据迁移工具	第 11 章
Hadoop	分布式计算框架	第3章
HDFS	分布式文件系统	第4章
MapReduce	分布式并行编程框架	第 7 章
HBase	分布式数据库	第 5 章
Hive	基于 Hadoop 的数据仓库	第8章
MySQL	关系数据库	附录 B
Spark	基于内存的分布式计算框架	第 9 章
MongoDB	文档数据库	第6章
Redis	键值数据库	第6章
Easel. ly	可视化工具	第 10 章
D3	可视化工具	第 10 章
魔镜	可视化工具	第 10 章
ECharts	可视化工具	第 10 章
Tableau	可视化工具	第 10 章
R	可视化工具	第 12 章

表 1-4 相关大数据软件在本书中的章节安排

需要说明的是,数据采集工具(Flume、Kafka、Sqoop)虽然是在大数据分析流程中的第一个环节,但是,由于这些工具需要和 Hadoop 和 Spark 等配合使用,因此,本书把数据采集工具 (Flume、Kafka、Sqoop)的介绍安排在后面的第 11 章中。在第 11 章中,介绍完 Flume、Kafka 和 Sqoop 的安装以后,会直接在第 11 章介绍如何对 Kafka 和 Spark 进行组合使用,然后,在第 12 章中,会使用 Sqoop 工具在 MySQL、HBase、Hive 之间进行数据相互导入导出。

# 1.5 在线资源

本书官网提供了全部配套资源的在线浏览和下载,官网地址是 http://dblab.xmu.edu.cn/post/bigdatapractice/。

#### 1.5.1 在线资源一览表

为了更好地学习和使用本书,官网上提供了下载专区、在线视频、拓展阅读等栏目,具体内容如表 1-5 所示。

官网栏目	内 容 说 明
下载专区	包含本书内各个章节所涉及的源代码和软件
在线视频	包含与本书配套的"大数据技术原理与应用"课程免费在线视频
拓展阅读	包含各种大数据技术在线教程
大数据课程 公共服务平台	提供大数据教学资源一站式"免费"在线服务,包括课程教材、讲义 PPT、课程习题、实验指南、学习指南、备课指南、授课视频和技术资料等

表 1-5 本书官网的栏目内容说明

#### 1.5.2 下载专区

"下载专区"栏目提供了本书内各个章节所涉及的源代码和软件的下载,为了方便读者查找相关软件和代码,表 1-6 给出了本书官网"下载专区"目录及其内容的概览。

表 1-6 本书官网"下载专区"目录及其内容概览

目录	文 件 清 单	
	apache-flume-1. 7. 0-bin. tar. gz	
	apache-hive-1. 2. 1-bin. tar. gz	
	apache-maven-3. 3. 9-bin. zip	
	eclipse-java-mars-2-win32-x86_64. zip	
	FileZilla_3. 17. 0. 0_win64_setup. exe	
	hadoop-2.7.1. tar. gz	
	hbase-1. 1. 5-bin. tar. gz	
	kafka_2. 10-0. 10. 1. 0. tgz	
	mongo-java-driver-3. 2. 2. jar	
	mongodb-linux-x86_64-ubuntu1604-3.2.7. tgz	
th (4	mysql-connector-java-5. 1. 40. tar. gz	
软件	putty_V0. 63. 0. 0. 43510830. exe	
	redis-3. 2. 7. tar. gz	
	sbt-launch. jar	
	SecurAble. exe	
	spark-1. 6. 2-bin-without-hadoop. tgz	
	spark-streaming_2. 10-1. 6. 2. jar	
	spark-streaming-kafka_2.10-1.6.2.jar	
	sqoop-1. 4. 6. bin_hadoop-2. 0. 4-alpha. tar. gz	
	Ubuntu16.04-hadoop2.7.1-spark1.6.2-XMU-linziyu-20161123.ova	
	ubuntukylin-16.04-desktop-amd64. iso	
	VirtualBox_5. 0. 10. 4061_104061_Win. 1448355141. exe	

目	录	文件清单	
	第3章	core-site. xml; hdfs-site. xml; mapred-site. xml; yarn-site. xml	
第:	第4章	HDFSCreateFile. java; HDFSFileIfExist. java; HDFSReadFile. java	
	第5章	HBaseOperation. java	
	第6章	MongoDBExample. java	
	第7章	WordCount. java	
代码	第8章	hive-site. xml	
	第9章	pom. xml; simple. sbt; SimpleApp. java; SimpleApp. scala	
	第 10 章	example1. html; example2. html; example3. html; example4. html; example5. html; example6. html; toolbox. html; d3. zip	
	第 11 章	avro. conf; example. conf; KafkaWordCount. scala; KafkaWordProducer. scala; simple. sbt; StreamingExamples. scala	
	第 12 章	ImportHBase. java; pre_deal. sh	
数据集	第 12 章	user. zip	
实验答案	附录 A	附录 A 大数据课程实验答案.pdf	

#### 1.5.3 在线视频

本书是笔者编写的另外一本教材《大数据技术原理与应用》的"姊妹篇"。

《大数据技术原理与应用》一书侧重于介绍大数据技术的实现原理,编程实践内容较少,该教材定位为入门级大数据教材,以"构建知识体系、阐明基本原理、开展初级实践、了解相关应用"为原则,旨在为读者搭建起通向大数据知识空间的桥梁和纽带,为读者在大数据领域深耕细作奠定基础、指明方向。教材系统论述了大数据的基本概念、大数据处理架构Hadoop、分布式文件系统HDFS、分布式数据库HBase、NoSQL数据库、云数据库、分布式并行编程模型MapReduce、大数据处理架构Spark、流计算、图计算、数据可视化以及大数据在互联网、生物医学和物流等各个领域的应用。

与《大数据技术原理与应用》一书不同,本书侧重于介绍大数据软件的安装、使用和基础编程方法,并提供了丰富的实验和案例。本书可以作为《大数据技术原理与应用》的配套教程,两本书组合使用,可以达到更好的学习效果。此外,本书也可以和市场上现有的其他大数据教材配套使用。

《大数据技术原理与应用》教材拥有配套的高清课程视频,共13讲,视频累计长度1300分钟。读者在学习本书的同时,可以通过观看在线视频,了解相关大数据技术的实现原理,从而更好实践大数据技术。为了让读者在学习本书时能够快速找到对应的在线视频内容,这里给出本书和在线视频之间的章节对应关系(见表1-7)。

本书章节	《大数据技术原理与应用》视频
第1章 大数据技术概述	第1讲 大数据概述
第 2 章 Linux 系统的安装和使用	无
第 3 章 Hadoop 的安装和使用	第 2 讲 大数据处理架构 Hadoop
第 4 章 HDFS 操作方法和基础编程	第 3 讲 分布式文件系统 HDFS
第 5 章 HBase 的安装和基础编程	第 4 讲 分布式数据库 HBase
第 6 章 典型 NoSQL 数据库的安装和使用	第5讲 NoSQL 数据库
第 7 章 MapReduce 基础编程	第 7 讲 MapReduce
第 8 章 数据仓库 Hive 的安装和使用	第 8 讲 基于 Hadoop 的数据仓库 Hive
第 9 章 Spark 的安装和基础编程	第 10 讲 Spark
第 10 章 典型的可视化工具的使用方法	无
第 11 章 数据采集工具的安装和使用	无
第 12 章 大数据课程综合实验案例	无

表 1-7 本书和在线视频之间的章节对应关系

#### 1.5.4 拓展阅读

本书只是简要介绍大数据软件安装和基础编程,如果要深入学习相关内容,可以访问本书官网的"拓展阅读"栏目,里面提供了相关的大数据技术在线教程。例如《Spark 入门教程》为读者开辟了一条学习 Spark 技术的捷径,扫除学习道路上的各种障碍,帮助读者降低学习难度,大幅度节省学习时间。该教程详细介绍了 Scala 语言、Spark 运行架构、RDD 的设计与运行原理、Spark 的部署模式、RDD 编程、键值对 RDD、数据读写、Spark SQL、Spark Streaming、Spark MLlib等。

#### 1.5.5 大数据课程公共服务平台

高校大数据课程公共服务平台(见图 1-5),旨在为全国高校教师和学生提供大数据教学资源一站式"免费"在线服务,包括课程教材、讲义 PPT、课程习题、实验指南、学习指南、备课指南、授课视频和技术资料等。平台重点打造"13 个 1 工程",即 1 本教材、1 个教师服务站、1 个学生服务站、1 个公益项目、1 堂巡讲公开课、1 个示范班级、1 门在线课程、1 个交流群(QQ 群和微信群)、1 个保障团队、1 个培训交流基地、1 个实验平台、1 个课程群和 1 个微信公众号。平台由厦门大学数据库实验室建设,自 2013 年 5 月建设以来,目前年访问量超过 100 万次,成为全国高校大数据教学知名品牌。



图 1-5 高校大数据课程公共服务平台的标志

## 1.6 本章小结

大数据技术是一个庞杂的知识体系,包含了大量相关技术和软件。在具体学习相关技术及其软件之前,非常有必要建立对大数据技术体系的整体性认识。因此,本章首先从总体上介绍了大数据关键技术和各类大数据软件。鉴于不同的大数据学习者有着不同的学习需求,为了方便读者迅速找到对应的学习章节,本章给出了本书的整体内容安排。此外,与本书配套的相关资源的建设,是帮助读者更加有效、高效学习本书的重要方面。因此,本章最后详细列出了与本书配套的各种丰富的在线资源,全部可以通过网络自由免费访问。

# 第2章

# Linux 系统的安装和使用

Hadoop 是目前处于主流地位的大数据软件,尽管 Hadoop 本身可以运行在 Linux、Windows 和其他一些类 UNIX 系统(如 FreeBSD、OpenBSD、Solaris 等)之上,但是,Hadoop 官方真正支持的作业平台只有 Linux。这就导致其他平台在运行 Hadoop 时,往往需要安装很多其他的包来提供一些 Linux 操作系统的功能,以配合 Hadoop 的执行。例如,Windows 在运行 Hadoop 时,需要安装 Cygwin 等软件。鉴于 Hadoop、Spark 等大数据软件大多数都是运行在 Linux 系统上,因此,本书采用 Linux 系统安装各种常用大数据软件、开展基础编程。

首先,本章简要介绍 Linux 系统;然后,详细介绍 Linux 系统的安装方法、Linux 系统及相关软件的基本使用方法,为后面章节内容的学习奠定基础;最后,给出关于教程内容的一些约定。

# 2.1 Linux 系统简介

Linux 是一套免费使用和自由传播的类 UNIX 操作系统,是一个基于 POSIX 和 UNIX 的多用户、多任务、支持多线程和多 CPU 的操作系统。Linux 有许多服务于不同目的的发行版,包括对不同计算机结构的支持、对一个具体区域或语言的本地化、实时应用和嵌入式系统等,已经超过 300 个发行版,但是,目前在全球范围内只有 10 个左右发行版被普遍使用,如 Fedora、Debian、Ubuntu、RedHat、SuSE、CentOS等。

Linux 的发行版本可以大体分为两类:一类是商业公司维护的发行版本;一类是社区组织维护的发行版本;前者以著名的 Redhat 为代表,后者以 Debian 为代表。Debian 是社区类 Linux 的典范,是迄今为止最遵循 GNU 规范的 Linux 系统。Ubuntu 严格来说不能算一个独立的发行版本,Ubuntu 是基于 Debian 的 unstable 版本加强而来的。Ubuntu 就是一个拥有 Debian 所有的优点以及自己所加强的优点的近乎完美的 Linux 桌面系统,在服务端和桌面端使用占比最高,网络上资料最齐全,因此,本书采用 Ubuntu。

# 2.2 Linux 系统安装

本节介绍 Linux 系统的安装方法,内容包括下载安装文件、Linux 系统的安装方式、安装 Linux 虚拟机、生成 Linux 虚拟机镜像文件等。

#### 2.2.1 下载安装文件

本书采用的 Linux 发行版是 Ubuntu,同时,为了更好地支持汉化(例如,更容易输入中文),这里采用 Ubuntu Kylin 发行版。Ubuntu Kylin 是针对中国用户定制的 Ubuntu 发行版本,里面包含一些中国特色的软件(如中文拼音输入法),并根据中国人的使用习惯,对系统做了一些优化。

可以通过两种途径下载 Ubuntu Kylin 发行版,第一种方式是进入 Windows 系统,访问 Ubuntu 官网下载(https://www.ubuntu.com/download/ubuntu-kylin)。进入 Ubuntu 官 网的下载页面后(见图 2-1),会提供两种不同版本的下载地址,即 32 位版本和 64 位版本。如果计算机硬件配置较低,内存小于 2GB,建议选择 32 位版本;如果内存大于 4GB,建议选择 64 位版本。

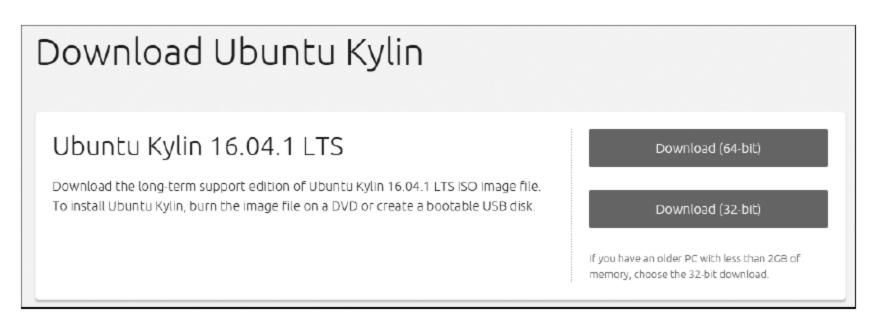


图 2-1 Ubuntu Kylin 官网下载页面

第二种方式是进入 Windows 系统,访问本书官网(http://dblab. xmu. edu. cn/post/bigdatapractice/),进入"下载专区",在"软件"目录下找到文件 ubuntukylin-16.04-desktop-amd64.iso 下载到本地。不过,本书官网仅提供了 64 位版本的 Linux 系统安装镜像文件。

Linux 系统安装文件一般都比较大,往往在1GB以上,因此,在下载Linux 系统安装文件时,建议使用支持断点续传的下载工具,如迅雷或者QQ旋风。

## 2.2.2 Linux 系统的安装方式

Linux 系统的安装主要有两种方式:虚拟机安装方式和双系统安装方式。

- (1)虚拟机安装方式。在 Windows 操作系统上安装虚拟机软件(如 VirtualBox 或 VMware),然后,在虚拟机软件之上安装 Linux 系统。采用这种安装方式时,Linux 系统就相当于运行在 Windows 上的一个软件。如果要使用 Linux 系统,需要在计算机开机后,首先启动进入 Windows 操作系统;然后,在 Windows 操作系统中打开虚拟机软件(如 VirtualBox);最后,在虚拟机软件中启动 Linux,之后才能使用 Linux 系统。
- (2)双系统安装方式。直接把 Linux 系统安装在计算机"裸机"上,而不是安装在 Windows 系统之上。采用这种安装方式时,Linux 系统和 Windows 系统的地位是平等的,当计算机开机时,屏幕上会显示提示信息,让用户选择要启动的系统:如果用户选择 Windows 系统,计算机就继续启动进入 Windows 系统;如果用户选择 Linux 系统,计算机就继续启动进入 Linux 系统。

对于虚拟机安装方式而言,由于同时要运行 Windows 系统和 Linux 系统,因此,这种安装方式对计算机硬件的要求较高。建议计算机较新且具备 4GB 以上内存时可以选择虚拟机安装方式。如果计算机较旧或配置内存小于 4GB 时,建议选择双系统安装方式;否则,在配置较低的计算机上运行 Linux 虚拟机,系统运行速度会非常慢。

由于大多数大数据初学者对 Windows 系统比较熟悉,对 Linux 系统可能稍显陌生,因此,本书采用虚拟机方式安装 Linux 系统。如果需要采用双系统方式安装,可以到网络搜索相关资料完成安装,这里不做介绍。

#### 2.2.3 安装 Linux 虚拟机

当采用虚拟机安装方式时,计算机一定要具备 4GB 以上的内存;否则,运行速度会很慢。计算机的硬盘配置需要在 100GB 以上。

#### 1. 检测 CPU 是否支持虚拟化

采用虚拟机安装方式时,需要提前测试计算机的 CPU 是否支持虚拟化。一般来说,近几年购买的计算机的 CPU 都是支持虚拟化的,不过,还是建议采用 SecurAble 软件进行测试。本书官网提供了 SecurAble 软件的下载,在"下载专区"的"软件"目录下,文件名是SecurAble.exe。

#### 1) CPU 支持虚拟化

运行 SecurAble 软件以后,如果得到如图 2-2 所示结果,则说明 CPU 支持 64 位系统, 支持虚拟化。



图 2-2 CPU 支持 64 位系统时的 SecurAble 检测结果

#### 2) 虚拟化在 BIOS 中没有开启

运行 SecurAble 软件以后,如果得到如图 2-3 所示的结果,则说明 CPU 支持 64 位系统;但是,虚拟化在 BIOS 中没有开启。

这时,就需要在 BIOS 中开启相关选项。关于如何修改 BIOS 以支持虚拟化,不同的计算机具有不同的方法。对于大部分计算机而言,只需要在开机的第一时间按下键盘上 Delete 键即可进入 BIOS 系统。图 2-4 显示了某款计算机的 BIOS 界面。

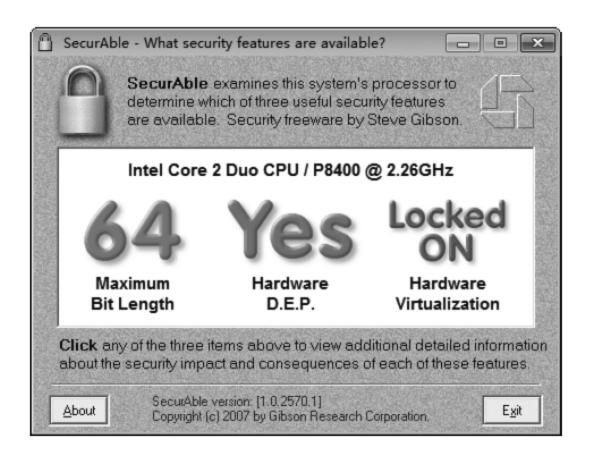


图 2-3 虚拟化在 BIOS 中没有开启时的 SecurAble 检测结果

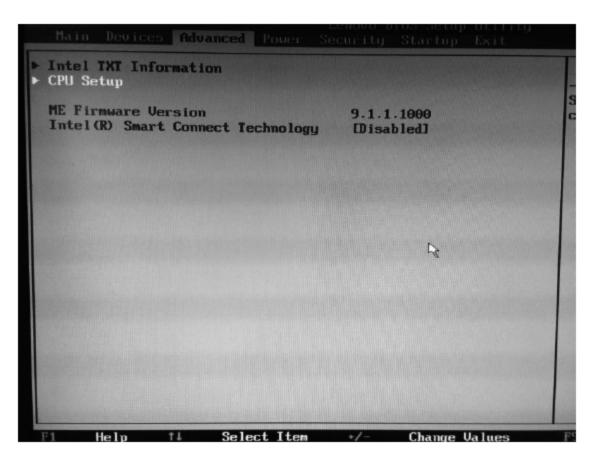


图 2-4 BIOS 界面

在该BIOS界面中,选择CPU Setup 就可以进入到CPU 的设置界面(见图 2-5),需要把Intel(R) Virtualization Technology 选项设置为 Enabled,这样就开启了虚拟化功能。

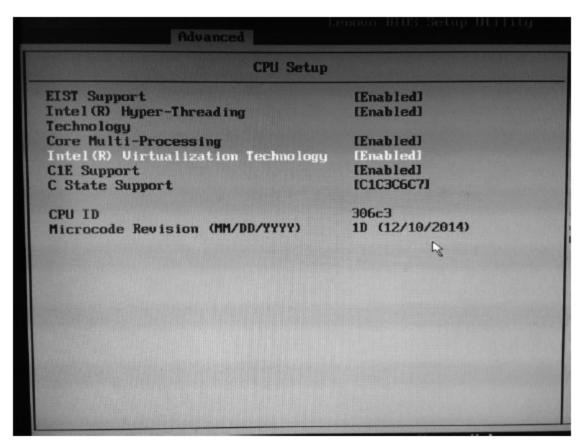


图 2-5 CPU 设置界面

如果出现的 BIOS 设置界面和本书不同,请参考相关网络资料修改 BIOS 配置。

#### 3) CPU 不支持虚拟化

运行 SecurAble 软件以后,如果得到如图 2-6 所示结果,一般情况下,意味着 CPU 不支持虚拟化,建议更换计算机。但是,也有例外,在实际使用该软件时,通过大量计算机的实际测试结果发现,存在一定比例的"误测"情况,也就是说,测试结果是"不支持虚拟化",实际上,计算机是支持虚拟化的。所以,当测试结果是"不支持虚拟化"时,也不要完全放弃,可以尝试继续按照本书后面的步骤安装 Linux 虚拟机,也许可以安装成功。

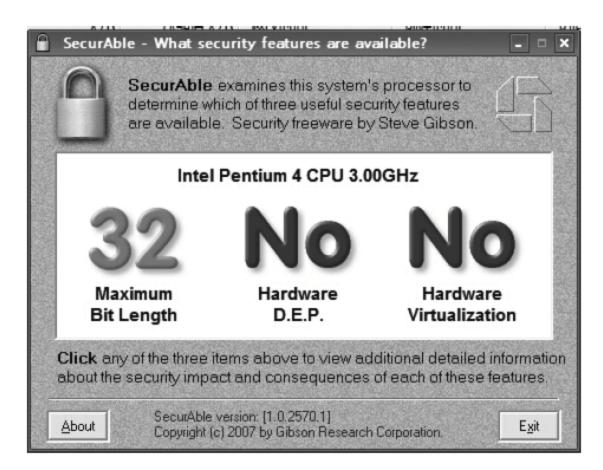


图 2-6 CPU 不支持虚拟化时的 SecurAble 检测结果

#### 2. 安装虚拟机软件

常用的虚拟机软件包括 VMware 和 VirtualBox 等,但是,VMware 属于商业软件,需要付费,因此,本书采用免费的开源软件 VirtualBox。可以到本书官网下载,位于"下载专区"的"软件"目录下,文件名是 VirtualBox\_5.0.10.4061\_104061\_Win.1448355141.exe。下载后,在 Windows 操作系统中安装 VirtualBox。根据大量计算机的实际安装情况,有部分计算机无法成功安装 VirtualBox,这时,请尝试获得商业软件 VMware 进行安装。总体而言,根据大量计算机的实际安装情况,部分计算机只能成功安装 VirtualBox 而无法成功安装 VMware,还有一部分计算机只能成功安装 VMware 而无法成功安装 VirtualBox。所幸的是,对于 VirtualBox 和 VMware 而言,当其中一款虚拟化软件在计算机上安装失败时,另一款虚拟化软件基本都会安装成功,在实际使用过程中,还没有出现这两款虚拟化软件都安装失败的情形。

#### 3. 安装 Linux 操作系统

本书仅介绍如何在 VirtualBox 上安装 Linux 系统,关于如何在 VMware 上安装 Linux 系统,请参考相关网络资料。

进入 Windows 系统,启动 VirtualBox 软件,按照以下两大步骤完成 Linux 系统的安装:首先需要创建一个虚拟机;然后,在虚拟机上安装 Linux 系统。

#### 1) 创建虚拟机

#### (1) 新建一个虚拟机。

打开 VirtualBox,如图 2-7 所示,单击"新建"按钮,创建一个虚拟机。

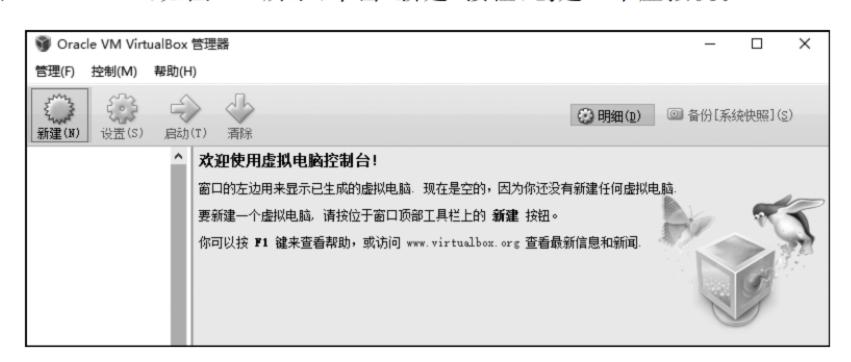


图 2-7 VirtualBox 首界面

#### (2) 设置虚拟机名称和系统类型。

在弹出来的对话框中(见图 2-8),在"名称"后面的文本框中输入虚拟机名称,例如,可以取名为 Ubuntu。在"类型"后面的下拉列表框中选择 Linux。如果选择的系统是 32 位 Ubuntu 系统,在"版本"后面的下拉列表框中选择 Ubuntu(32bit);如果选择的系统是 64 位 Ubuntu 系统,在"版本"后面的下拉列表框中选择 Ubuntu(64bit);本书采用的是 64 位 Ubuntu 系统。然后,单击"下一步"按钮。

#### (3)设置虚拟机内存大小。

可以根据计算机的内存情况来设置虚拟机内存大小。如果计算机总内存为 4GB(见图 2-9),可以划分 1GB的内存给虚拟机来运行 Ubuntu(实际上,在这种配置下运行虚拟机以后,仍会稍显卡顿,建议计算机总内存增加到 8GB以上)。如果计算机总内存有 8GB,那么可以划分 3GB 内存给 Ubuntu,这样运行速度会快很多。设置好以后,单击"下一步"按钮。



图 2-8 VirtualBox 新建虚拟机界面

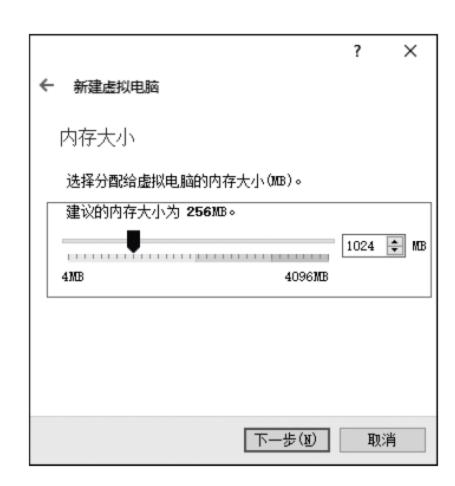


图 2-9 内存大小设置界面

#### (4) 创建虚拟硬盘。

在弹出的界面中(见图 2-10)选择"现在创建虚拟硬盘"单选按钮,然后单击"创建"按钮。

在弹出的界面中(见图 2-11)选择"VDI(VirtualBox 磁盘映像)"单选按钮,然后单击"下一步"按钮。

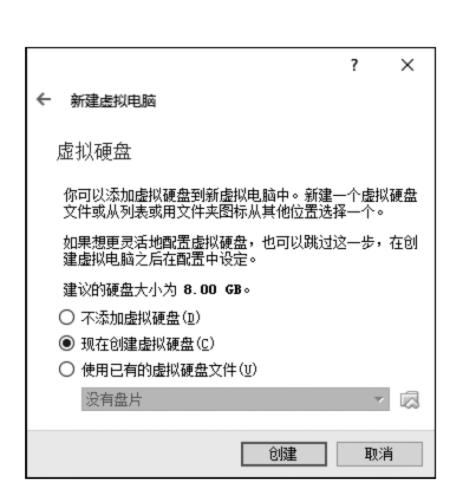


图 2-10 创建虚拟硬盘界面

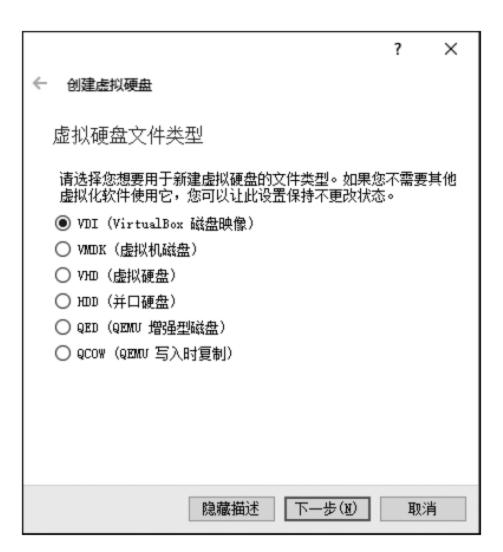


图 2-11 设置虚拟硬盘文件类型界面

在弹出的界面中(见图 2-12)选择"动态分配"单选按钮,然后单击"下一步"按钮。

随后需要在弹出的界面中(见图 2-13)选择文件存储的位置和容量大小。本书需要安装常用的大数据软件(包括 Hadoop、HBase、Hive、Spark 等),大概需要划分 20GB(建议 40GB)用于文件存储,然后单击"创建"按钮。

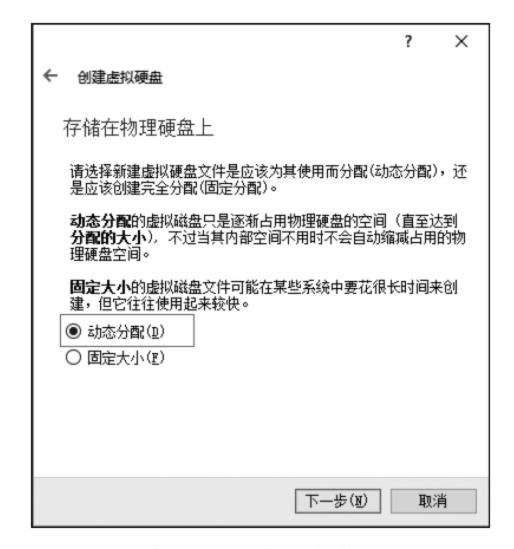


图 2-12 虚拟硬盘文件动态分配设置界面

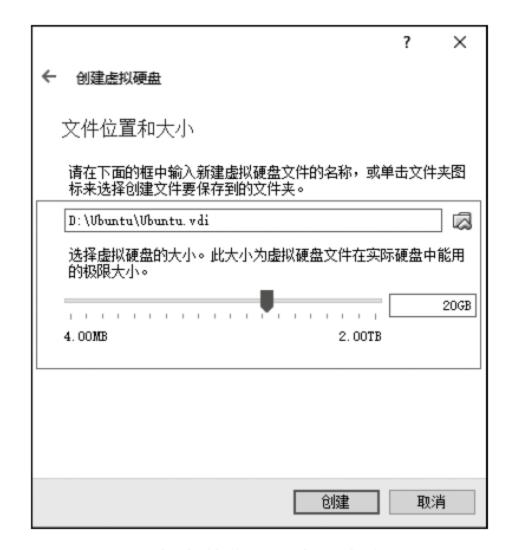


图 2-13 文件存储位置和容量大小设置界面

到此为止,就完成了虚拟机的创建,然后,就可以在这个新建的虚拟机上安装 Linux 系统。

2) 在虚拟机上安装 Linux 系统

按照上面的步骤完成虚拟机的创建以后,会返回到如图 2-14 所示的界面。



图 2-14 虚拟机创建完成以后的界面

这时请勿直接单击"启动"按钮,否则,有可能会导致进程中断。应该首先设置"存储",单击图 2-14 中的"存储"按钮,打开存储设置界面(见图 2-15)。然后单击"没有盘片",再单击光盘按钮,选择"选择一个虚拟光盘",找到之前已经下载到本地的 Ubuntu 系统安装镜像文件 ubuntukylin-16.04-desktop-amd64.iso,单击"确定"按钮。

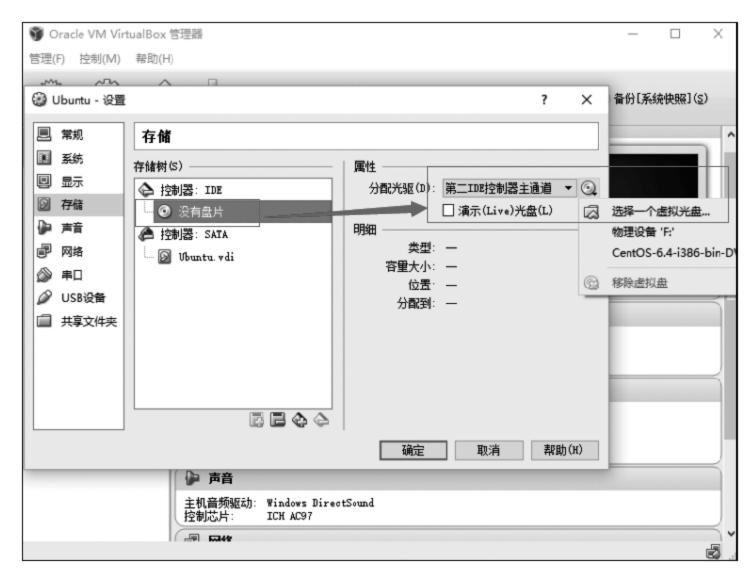


图 2-15 选择虚拟光盘界面

在界面中(见图 2-16)选择刚创建的虚拟机 Ubuntu,单击"启动"按钮。



图 2-16 加载了虚拟光盘后的 VirtualBox 界面

启动后如果看到如图 2-17 所示的界面,在下拉列表框中选择 ISO 文件 ubuntukylin-16.04-desktop-amd64.iso,单击"启动"按钮。如果没有出现此界面,直接跳往下一步即可。



图 2-17 VirtualBox 虚拟机启动后可能出现的界面

启动后会看到 Ubuntu 的安装欢迎界面(见图 2-18),选择操作系统语言,推荐使用中文(简体),然后单击"安装 Ubuntu"按钮。

然后在如图 2-19 所示的界面中,检查是否连接网络、是否安装第三方软件。如果此时网络不可用,则会显示叉号。这里不需要联网也可以顺利完成安装,并且不需要安装第三方软件。最后单击"继续"按钮。



图 2-18 Ubuntu 安装欢迎界面



图 2-19 检查是否连接网络和安装第三方软件的界面

在如图 2-20 所示的界面中,需要确认安装类型,这里选择"其他选项",然后单击"继续"按钮。

在如图 2-21 所示的界面中,单击"新建分区表"按钮。



图 2-20 安装类型选择界面



图 2-21 安装类型界面

在弹出的界面中(见图 2-22)单击"继续"按钮。

下面开始创建分区,添加交换空间和根目录。一般来说,可以选择 512MB~1GB 作为交换空间,剩下空间全部用来作为根目录。在图 2-23 中单击选中"空闲",然后再单击十按钮,创建交换空间。

单击+按钮后,会出现如图 2-24 所示的界面,可以进行如下设置。

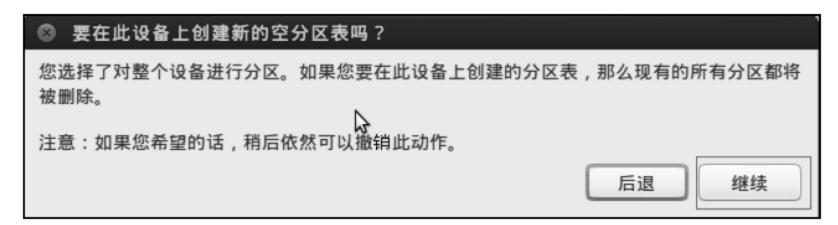


图 2-22 新建分区表确认界面



图 2-23 创建交换空间界面



图 2-24 交换空间的分区设置界面

- (1) 大小:设置为 512MB。
- (2) 新分区的类型:选择"主分区"选项。
- (3) 新分区的位置:选择"空间起始位置"选项。
- (4) 用于: 在下拉列表中选择"交换空间"选项。

设置完成后单击"确定"按钮。

下面开始创建根目录。在图 2-25 中单击选中"空闲",然后再单击+按钮,创建根目录。



图 2-25 创建根目录界面

单击+按钮后,会出现如图 2-26 所示的界面,可以进行如下设置。

- (1) 大小: 不用改动,系统自动设为剩余的空间。
- (2) 新分区的类型:选择"逻辑分区"选项。
- (3) 新分区的位置:选择"空间起始位置"选项。
- (4) 用于: 在下拉列表中选择"Ext4 日志文件系统"选项。
  - (5) 挂载点: 在下拉列表中选择/选项。

设置完成后单击"确定"按钮。

在出现的界面中(见图 2-27)单击"现在安装" 按钮。

单击"现在安装"按钮后,会弹出如图 2-28 所示的界面,询问"将改动写入磁盘吗?",单击"继续"按钮。



图 2-26 根目录的分区设置界面



图 2-27 "现在安装"界面



图 2-28 询问界面

如果需要在弹出的界面(见图 2-29)中选择时区,这里采用默认值 Shanghai 即可。然后单击"继续"按钮。



图 2-29 选择时区界面

在弹出的界面中(见图 2-30)选择键盘布局,左右栏目都选择"汉语"即可。



图 2-30 选择键盘布局界面

如果需要在弹出的界面(见图 2-31)中设置用户名和密码。建议选择"登录时需要密码"单选按钮。由于现在处于学习阶段,不需要考虑安全问题,密码建议使用一位的密码(如把密码设置为 1),这样在安装软件需要输入密码的时候会比较方便。本书设置用户名为dblab。然后单击"继续"按钮。



图 2-31 设置用户名和密码界面

单击"继续"按钮后会出现图 2-32 所示的界面,现在安装过程就正式开始了,系统会自动安装,不要单击 Skip 按钮,请耐心等候系统自动安装完成。

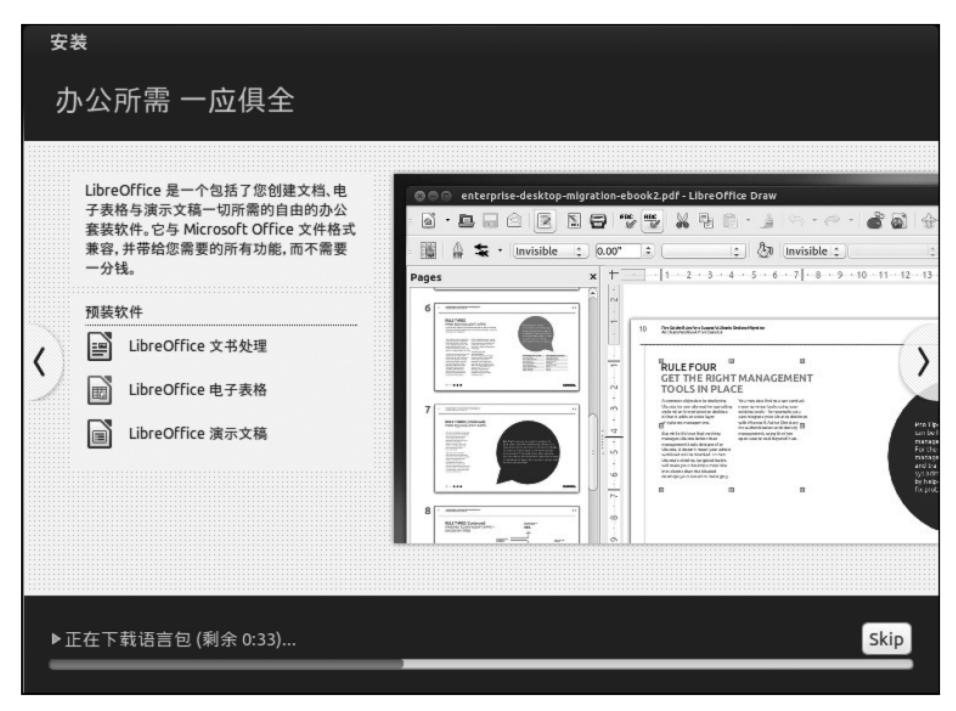


图 2-32 安装过程正式开始的界面

安装完成以后(见图 2-33)单击"现在重启"按钮即可。"现在重启"只是重启虚拟机系统的运行,并不是重启 Windows 系统。

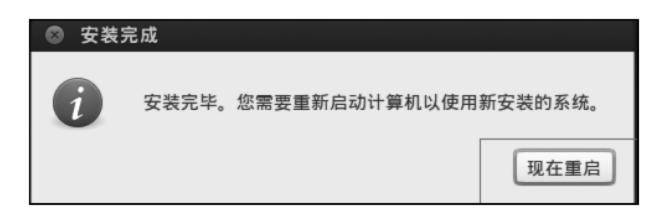


图 2-33 提示"现在重启"界面

重启以后就可以进入到 Ubuntu 系统的登录界面(见图 2-34),输入刚才创建的用户名和密码,就可以进入 Ubuntu 系了。

至此,Linux系统就成功安装完成。

进入 Linux 系统以后,如果要关闭系统,可以单击系统界面右上角的"齿轮"图标,单击后会弹出如图 2-35 所示的界面,单击"关机"选项,就可以关闭 Linux 系统。关闭 Linux 虚拟机后,还需要继续手动关闭 VirtualBox 软件。注意,采用虚拟机方式安装 Linux 系统, Linux 虚拟机可以被视为运行在 Windows 系统上的一个软件,关闭 Linux 虚拟机,只相当于关闭了 Windows 系统上面的一个软件,Windows 系统本身还会继续正常运行。



图 2-34 登录界面



图 2-35 Linux 系统菜单

- 3) 可能出现的问题及其解决方法
- (1) 启动时出现错误。

启动 Linux 虚拟机时可能会出现图 2-36 所示的提示界面,然后,一直停在那里不动,表现出类似"死机"的状态。

```
wait–for–state stop/waiting
                                                                           [ OK ]
                            * Stopping rsync daemon rsync
 speech-dispatcher disabled; edit /etc/default/speech-dispatcher
                                                                   ∗ Asking all r
emaining processes to terminate...
                                                                           [ OK ]
* All processes ended within 4 seconds...
                                                                           [ OK ]
nm-dispatcher.action: Caught signal 15, shutting down...
* Unmounting temporary filesystems...
                                                                           [ OK ]
ModemManager[1295]: <info> Caught signal, shutting down...
ModemManager[1295]: <warn> Could not acquire the 'org.freedesktop.ModemManager1
 service name
 * Deactivating swap...
 * Stopping early crypto disks
                                                                           [ OK ]
```

图 2-36 Linux 虚拟机启动时的提示信息

遇到这种情况时,可以单击 VirtualBox 软件界面右上角的叉号,会弹出如图 2-37 所示的界面。

可以选择"强制退出"单选按钮,单击"确定"按钮后强行结束虚拟机。

(2) 屏幕分辨率低的问题。

虚拟机启动后,Ubuntu 系统默认是以窗口模式打开,而且分辨率很低。如果无法接受较低的分辨率,那么可以进行适当设置,获得更大的屏幕分辨率。如图 2-38 所示,单击 VirtualBox 菜单中的"设备"选项,选择"安装增强功能",系统便会自动安装好增强的功能,如果出现提示需要确认,则输入 return 即可。



图 2-37 关闭虚拟机的界面



图 2-38 设备菜单

然后在 Ubuntu 系统桌面中,在快捷启动按钮中单击"终端"按钮(把鼠标放在按钮上,就会显示出按钮的快捷功能,见图 2-39),启动一个终端,进入 Shell 命令提示符状态,可以在里面输入和执行各种 Linux 命令。



图 2-39 快速启动栏

为了获得更高的屏幕分辨率,在终端中输入如下命令:

\$sudo apt-get install virtualbox-guest-dkms

最后可以在终端中输入 exit 退出终端,返回到 Ubuntu 系统桌面。在系统桌面中单击顶部菜单最右边的"齿轮"按钮,在弹出的界面中,选择"关机"选项即可,然后,在弹出的界面中选择"重启"。

重启后再次登录 Ubuntu 系统,单击系统桌面右上角的"齿轮"按钮,在弹出的界面中单击"系统设置"选项,会弹出如图 2-40 所示的界面。

单击"显示"图标按钮,出现如图 2-41 所示的界面。

在这个界面中,可以设置合适的分辨率,设置好后单击右下角的"应用"按钮,会弹出如图 2-42 所示的界面,单击"保持当前配置"就完成了分辨率的修改。

#### (3) 网络无法连接问题。

按照上述过程完成 Ubuntu 系统安装以后,大部分计算机都可以正常上网,访问互联网。但是,仍然会有部分计算机可能会出现无法访问互联网的情况,就无法下载各种软件和更新。如果出现无法连接互联网的情况,就需要对虚拟机的网络配置进行修改。需要进入 VirtualBox 的"设置",然后,选择配置"网络",在连接方式中选择"桥接网卡"。这样,启动进入 Ubuntu 以后,就可以使用网络了。



图 2-40 系统设置界面



图 2-41 显示器设置界面

需要注意的是,采用虚拟机方式安装 Linux 系统时,当在 Windows 中运行 Linux 虚拟机时,起初 Linux 虚拟机能够正常连接互联网,但是,一旦把计算机休眠或者待机时,再次把计算机唤醒进入工作状态以后,可能会出现 Windows 系统可以正常联网但是 Linux 虚拟机无法联网的情况,这时,只能关闭 Linux 虚拟机,再次重新启动虚拟机,然后 Linux 虚拟机可以正常联网。



图 2-42 显示器配置更改后的提示界面

#### 4. 利用 FIP 软件向 Ubuntu 传输文件

由于大多数大数据初学者对 Windows 系统比较熟悉,因此,本书采用虚拟机方式安装 Linux 系统(即 Ubuntu 系统)。在后续的学习过程中,经常需要把一些资料从 Windows 系统中传输到 Ubuntu 系统中,因此,这里介绍具体的实现方法。

#### 1) 设置网络连接方式

按照前面的虚拟机安装方法完成 Ubuntu 系统安装以后, Ubuntu 系统可以顺利访问互联网,例如,这时进入 Ubuntu 系统,打开一个浏览器(如默认安装好的火狐浏览器),就可以访问新浪、百度、腾讯等网站了。但是,这时 Windows 系统中的一些软件(比如 FTP),无法连接到 Ubuntu 系统,为什么呢?

在解答这个问题之前,要先关闭虚拟机,关闭 VirtualBox 软件。然后,重新打开 VirtualBox 软件,在 VirtualBox 界面的左上角,单击"齿轮"图标的"设置"按钮,打开设置界面,在左边栏目中选择"网络",会出现如图 2-43 所示的设置界面。

可以看出,这时的网络连接方式是"网络地址转换(NAT)"。如果把 Windows 系统称为"主机",把 VirtualBox 上的 Ubuntu 系统称为"虚拟机",采用这种连接方式时,虚拟机可以访问主机,但是,主机无法访问虚拟机。所以,在这种连接方式下,Windows 系统上的FTP 软件是无法连接访问 Ubuntu 系统中的 FTP 服务器的。

为了让虚拟机能够访问主机,同时让主机也能够访问虚拟机,就必须更改网络连接方式。如图 2-44 所示,需要在"连接方式"中选择"桥接网卡",在"界面名称"后面的下拉列表框中选择计算机当前连接到互联网的网卡,然后,单击"确定"按钮。经过上述设置后,再启动进入 Ubuntu 系统,就可以让主机访问虚拟机了。

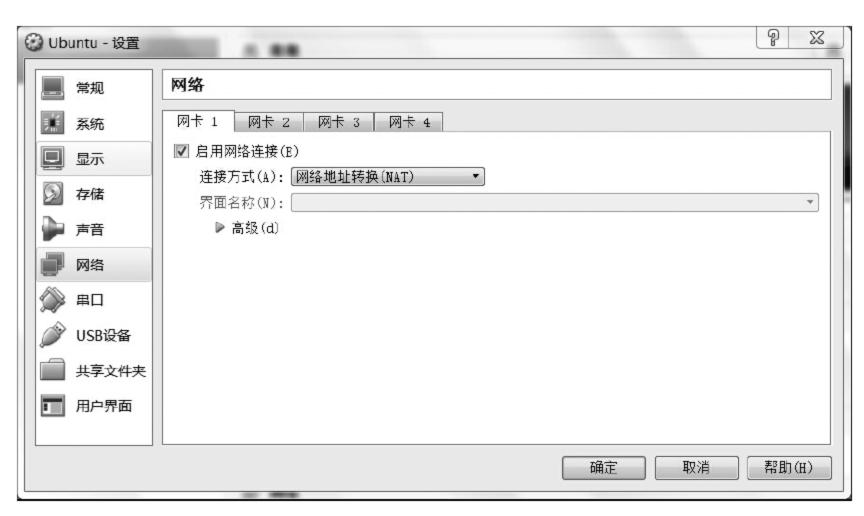


图 2-43 VirtualBox 网络设置界面

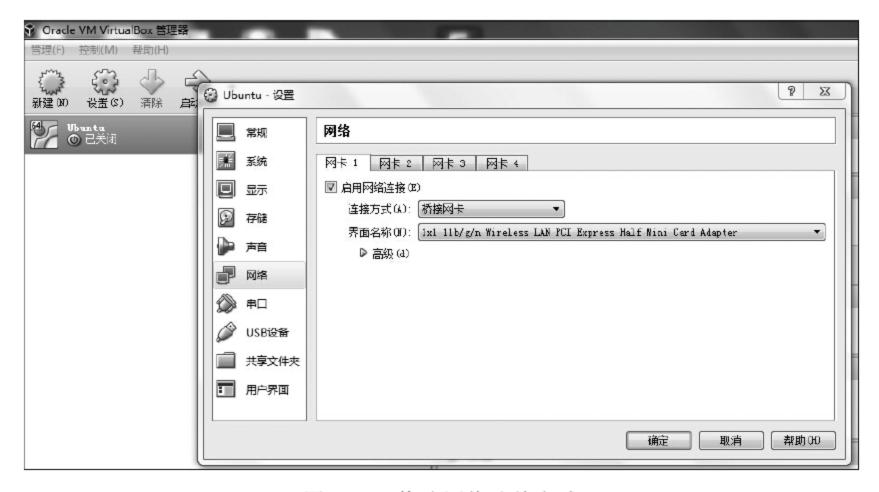


图 2-44 修改网络连接方式

#### 2) 设置 FTP 软件

本书采用的 FTP 软件是 FileZilla,可以登录 Windows 系统打开浏览器,访问本书官网进行下载,FileZilla 安装文件位于"下载专区"的"软件"目录下,文件名是 FileZilla\_3.17.0.0 \_win64\_setup.exe。下载到 FileZilla 安装文件以后,安装在 Windows 系统上。

为了能够让 FTP 软件连接到 Linux 虚拟机(Ubuntu 系统),需要获得 Linux 虚拟机的 IP 地址。登录 Windows 系统,打开虚拟机软件 VirtualBox,登录 Ubuntu 系统,然后,打开一个终端(可以使用快捷键 Ctrl+Alt+T),进入 Shell 命令提示符状态,输入命令 ifconfig,会得到如图 2-45 所示的结果。其中,"inet 地址:192.168.0.104"表示 Linux 虚拟机的 IP 地址是 192.168.0.104。每次重新启动虚拟机,或者在不同的地方(实验室或者宿舍)启动虚拟机,IP 地址都可能会发生变化,所以,每次登录 Ubuntu 系统以后,都需要重新查询 IP 地址。

```
    ★ □ 终端 文件(F) 编辑(E) 查看(V) 搜索(S) 终端(T) 帮助(H)
    hadoop@dblab-VirtualBox:~$ ifconfig enp0s3 Link encap:以太网 硬件地址 08:00:27:de:ba:51 inet 地址:192.168.0.104 广播:192.168.0.255 掩码:255.255.255.0 inet6 地址: fe80::bd3f:14fe:f3f4:9725/64 Scope:Link UP BROADCAST RUNNING MULTICAST MTU:1500 跃点数:1 接收数据包:43 错误:0 丢弃:0 过载:0 帧数:0 发送数据包:116 错误:0 丢弃:0 过载:0 载波:0 碰撞:0 发送队列长度:1000 接收字节:7782 (7.7 KB) 发送字节:12293 (12.2 KB)
    lo Link encap:本地环回 inet 地址:127.0.0.1 掩码:255.0.0.0 inet6 地址::://128 Scope:Host UP LOOPBACK RUNNING MTU:65536 跃点数:1 接收数据包:234 错误:0 丢弃:0 过载:0 帧数:0 发送数据包:234 错误:0 丢弃:0 过载:0 载波:0 帧数:0 发送数据包:234 错误:0 丢弃:0 过载:0 载波:0 标数:0 按达数据包:234 错误:0 丢弃:0 过载:0 载波:0 标数:0 发送数据包:234 错误:0 丢弃:0 过载:0 载波:0 标数:0 发送数据包:234 错误:0 丢弃:0 过载:0 载波:0 标数:0 经送数据包:234 错误:0 丢弃:0 过载:0 载波:0 标数:0 经过程:0 发送队列长度:1 接收字节:19651 (19.6 KB)
```

图 2-45 在 Linux 系统中查询 IP 地址

获得 Linux 虚拟机 IP 地址信息以后,就可以使用 FTP 软件 FileZilla 连接 Linux 虚拟机了。打开 FileZilla,启动后的界面如图 2-46 所示。



图 2-46 FileZilla 启动后的界面

单击界面左上角菜单的"文件"选项,在弹出的菜单中选择"站点管理器",会出现如图 2-47 所示的界面,用于设置 FTP 连接参数。



图 2-47 FTP 软件设置界面

单击界面左下角的"新站点"按钮,然后,开始设置各种连接参数,具体如下。

- (1) 主机:设置为 Linux 虚拟机的 IP 地址 192.168.0.104。
- (2) 端口:可以空着,使用默认端口。
- (3) 协议: 选择 SFTP-SSH File Transfer Protocol。
- (4) 登录类型:选择"正常"。
- (5) 用户: 可以使用之前安装 Ubuntu 系统时创建的用户名。
- (6) 密码:可以使用之前安装 Ubuntu 系统时创建的用户密码。

设置完成以后,单击界面下边的"连接"按钮,开始连接 Linux 虚拟机。连接成功以后,会显示如图 2-48 所示的界面,就可以使用 FTP 软件 FileZilla 向 Ubuntu 系统中传输文件了。



图 2-48 连接成功后的 FTP 软件界面

从图 2-48 中可以看出,FileZilla 连接成功以后的界面包括两个主要区域。其中,左侧的"本地站点"区域,会显示 Windows 系统中的目录,单击某个目录以后,下面就会显示目录中的文件信息。右边的"远程站点"区域,是 Linux 虚拟机中的目录,可以选择一个目录,作为文件上传后要存放的位置。当需要把 Windows 中的某个文件上传到 Linux 虚拟机中时,首先在"远程站点"中选择好上传后的文件所要存放的目录;然后,在"本地站点"中选择需要上传的文件,并在该文件名上右击,在弹出的菜单中选择"上传",就可以轻松完成文件的上传操作。如果要把 Linux 虚拟机中的某个文件下载到 Windows 系统中,可以首先在"本地站点"中选择好下载后的文件所要存放的目录,然后,在"远程站点"中找到要被下载的文件,在文件名上右击,在弹出的菜单中选择"下载",就可以完成文件的下载。

这里需要注意的是,Linux 系统对文件访问权限有着严格的规定,如果目录和文件的访问权限没有授权给某个用户,那么,该用户是无法访问这些目录和文件的。所以,当使用FileZilla 连接 Linux 虚拟机时,如果采用用户名 hadoop 连接,那么,就只能把文件上传到Ubuntu 系统中 hadoop 用户的主目录,也就是/home/hadoop 目录,是无法对其他目录进行

操作的,企图把文件传输到其他目录下就会失败。如果要顺利传输到其他目录,就必须登录 Ubuntu 系统,使用 root 权限把某个目录的权限赋予给 hadoop 用户(后面的 Linux 系统基本命令会涉及为用户授权的方法)。

#### 2.2.4 生成 Linux 虚拟机镜像文件

采用虚拟机方式安装好 Linux 系统以后,后面还会在 Linux 系统中继续安装大量的其他软件,进行各种各样费时费力的配置。因此,一个安装成功以后能够正常运行各种大数据

软件的 Linux 系统,已经具有备份和传播的价值,我们可以把系统导出成镜像文件,然后,在其他计算机上,就可以直接导入镜像文件,立即就可以完成 Linux 系统的安装,而且里面已经包含了大量大数据软件,这样就大大节省了系统和软件安装时间;此外,导出的镜像文件,也可以作为系统备份,一旦系统出现问题,就可以立即导入镜像文件,重新生成系统,省时省力。

#### 1. 导出生成镜像文件

打开虚拟机软件 VirtualBox,单击界面左上角的"管理"菜单,会弹出如图 2-49 所示的子菜单。

在这个子菜单中单击"导出虚拟电脑",出现如图 2-50 所示的界面。



图 2-49 VirtualBox 的管理菜单



图 2-50 导出虚拟机界面

单击"下一步"按钮会弹出如图 2-51 所示的界面。

在存储设置界面中的"文件"后面的文本框中设置镜像文件的存储位置,在"格式"后面选择生成镜像文件的格式,如 OVF 1.0。然后,单击"下一步"按钮,会弹出如图 2-52 所示的界面。

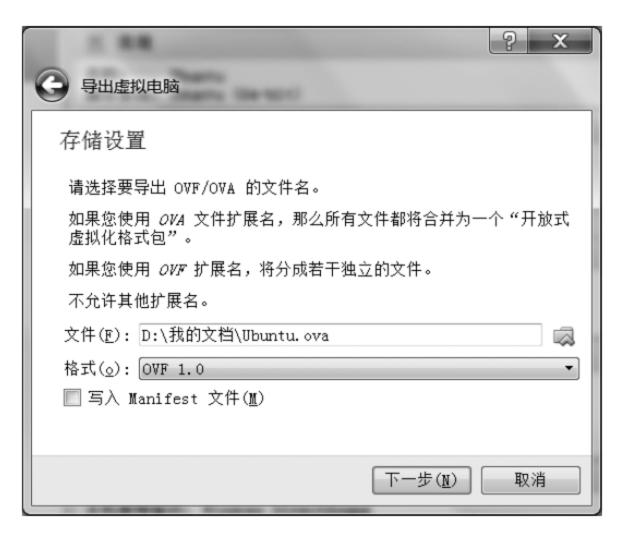


图 2-51 存储设置界面

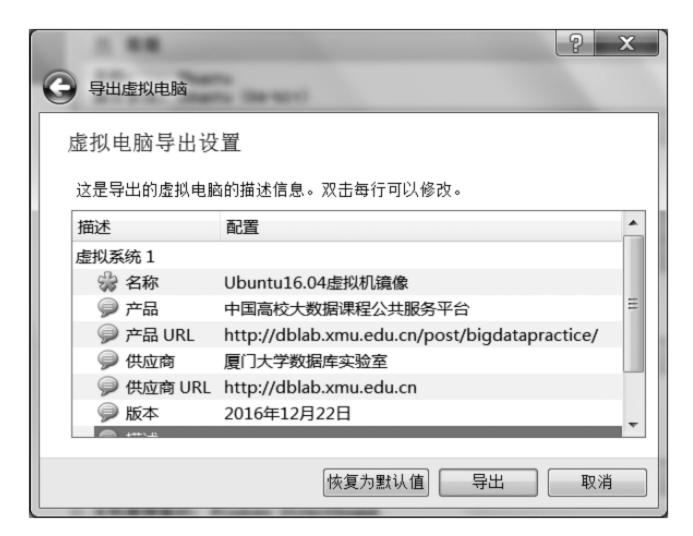


图 2-52 虚拟机导出设置界面

在该界面中单击底部的"导出"按钮,就可以生成 Linux 虚拟机镜像文件。

本书官网提供了一个已经制作完成的 Linux 虚拟机镜像文件,文件名是 Ubuntu16.04-hadoop2.7.1-spark1.6.2-XMU-linziyu-20161123.ova。下载该镜像文件后,打开VirtualBox软件,就可以导入生成 Linux 虚拟机。该镜像文件所包含的 Linux 虚拟机,包括以下系统和软件: Ubuntu 16.04、Hadoop 2.7.1、HBase 1.1.5、MongoDB 3.2.7、Eclipse 3.8和 Spark 1.6.2等。该虚拟机镜像文件仅供参考,为了更好地学习大数据软件的安装和使用,建议读者在初学阶段不要直接使用镜像文件生成 Linux 系统,最好按照本书逐步安装Linux 系统和各种大数据软件。在学习完本书以后,后期如果需要快速安装Linux 系统和大数据软件时,再使用本书提供的虚拟机镜像文件。

#### 2. 导入 Linux 虚拟机镜像文件

导入 Linux 虚拟机镜像文件的操作比较简单,打开虚拟机软件 VirtualBox,单击界面左上角的"管理"菜单,在弹出的子菜单中选择"导入虚拟电脑";然后,在弹出的界面中找到虚拟机镜像文件,单击"下一步"按钮,在弹出的界面中单击"导入"按钮,就可以顺利完成导入,生成一个可用的 Linux 虚拟机。设置完成后,就可以启动这个虚拟机,登录 Linux 系统。

# 2.3 Linux 系统及相关软件的基本使用方法

下面介绍 Linux 系统中需要了解的相关知识以及基本使用方法,以确保后续顺利学习和使用 Linux 系统及各种大数据软件。

#### 2.3.1 Shell

Shell 是 Linux 系统的用户界面,提供了用户与 Linux 系统内核进行交互操作的一种接口,它接收用户输入的命令并把它送入内核去执行。当人们在 Linux 系统中打开一个终端(可以采用快捷键 Ctrl+Alt+T)时,就进入了 Shell 命令提示符状态,在里面输入的用户命令,都会被送入 Linux 内核去执行。每个 Linux 系统的用户可以拥有自己的 Shell,用以满足他们自己专门的 Shell 需要。正如 Linux 本身拥有很多发行版一样, Shell 也有多种不同的版本,主要有下列版本的 Shell。

- (1) Bourne Shell: 由贝尔实验室开发。
- (2) BASH: 是 GNU 的 Bourne Again Shell,是 GNU 操作系统上默认的 Shell。
- (3) Korn Shell: 是对 Bourne Shell 的发展,在大部分内容上与 Bourne Shell 兼容。
- (4) C Shell: 是 SUN 公司 Shell 的 BSD 版本。
- (5) Z Shell: Z 是最后一个字母,也就是终极 Shell,集成了 BASH、ksh 的重要特性,同时又增加了自己独有的特性。

## 2.3.2 root 用户

对于 Linux 系统而言,超级用户一般命名为 root,相当于 Windows 系统中的 Administrator 用户。root 是系统中唯一的超级用户,具有系统中所有的权限,如启动或停止一个进程、删除或增加用户、增加或者禁用硬件等。Linux 中的 root 用户比 Windows 的 Administrator 用户的能力更大,足以把整个系统的大部分文件删掉,导致系统完全毁坏,不能再次使用。所以,用 root 进行不当的操作是相当危险的,轻微的可以造成死机,严重的甚至不能开机。因此,在实际使用中,除非确实需要,一般情况下都不推荐使用 root 用户登录 Linux 系统进行日常的操作。建议单独建立一个普通的用户,来学习大数据软件安装和开展编程实践。例如,本书全部采用单独建立的 hadoop 用户来开展实验。

# 2.3.3 创建普通用户

本书需要创建一个名称为 hadoop 的普通用户,后续所有操作都会使用该用户名登录到

Linux 系统。刚才我们在安装 Linux 系统时,设置了一个名称为 dblab 的用户,现在就可以使用 dblab 用户登录 Linux 系统;然后打开一个终端(可以使用快捷键 Ctrl+Alt+T),使用如下命令创建一个用户 hadoop:

\$sudo useradd -m hadoop -s /bin/bash

这条命令创建了可以登录的 hadoop 用户,并使用 /bin/bash 作为 Shell。接着使用如下命令为 hadoop 用户设置密码:

\$sudo passwd hadoop

由于是处于学习阶段,不需要把密码设置得过于复杂,本书把密码简单设置为 hadoop,即用户名和密码相同,方便记忆。需要按照提示输入两次密码。

然后可为 hadoop 用户增加管理员权限,以方便部署,避免一些对于新手来说比较棘手的权限问题,命令如下:

\$sudo adduser hadoop sudo

最后单击屏幕右上角的"齿轮"图标,选择"注销",注销当前登录的 dblab 用户,返回到 Linux 系统的登录界面(见图 2-53)。在登录界面中选择刚创建的 hadoop 用户并输入密码进行登录。



图 2-53 Linux 系统登录界面

再次说明本书以后学习过程中全部采用 hadoop 用户登录 Linux 系统。

## 2.3.4 sudo 命令

sudo 是 Linux 系统的管理指令,管理员可以授权给一些普通用户去执行一些需要 root

权限执行的操作。这样不仅减少了 root 用户的登录和管理时间,同样也提高了安全性。本书后面在执行软件安装时,都是采用 hadoop 用户登录,而不是 root 用户登录。因此,使用hadoop 用户登录 Linux 系统以后,当需要执行只有 root 用户有权限执行的命令时,都要在命令前面加上 sudo,才能够顺利执行,如果不加上 sudo,就会被拒绝执行。当使用 sudo命令时,会要求输入当前用户的密码。需要注意的是,Windows 系统中,用户输入密码,都会在屏幕上显示\*号作为反馈,但是,在 Linux 系统中,当输入密码时,不会在屏幕上显示\*号作为反馈,这时,不要误以为系统死机或者键盘出了问题,只要输完密码后按 Enter 键即可。

## 2.3.5 常用的 Linux 系统命令

本书以"最小化学习"为基本原则,只介绍本书后续学习过程需要用到的 Linux 命令,并以实例的形式进行介绍(见表 2-1),更多其他 Linux 命令请参考其他网络资料和书籍。

命令	含 义			
cd /home/hadoop	把/home/hadoop 设置为当前目录			
cd	返回上一级目录			
cd ~	进入到当前 Linux 系统登录用户的主目录(或主文件夹)。在 Linux 系统中,~代表的是用户的主文件夹,即"/home/用户名"这个目录,如果当前登录用户名为 hadoop,则~就代表 /home/hadoop/这个目录			
ls	查看当前目录中的文件			
ls -l	查看文件和目录的权限信息			
cat /proc/version	查看 Linux 系统内核版本信息			
cat /home/hadoop/word.txt	把/home/hadoop/word. txt 这个文件全部内容显示到屏幕上			
cat file1 file2>file3	把当前目录下的 file1 和 file2 两个文件进行合并生成文件 file3			
head -5word. txt	把当前目录下的 word. txt 文件中的前 5 行内容显示到屏幕上			
cp /home/hadoop/word.txt /usr/local/	把/home/hadoop/word.txt 文件复制到/usr/local 目录下			
rm ./word. txt	删除当前目录下的 word. txt 文件			
rm - r./test	删除当前目录下的 test 目录及其下面的所有文件			
rm - r test *	删除当面目录下所有以 test 开头的目录和文件			
ifconfig	查看本机 IP 地址信息			
exit	退出并关闭 Linux 终端			

表 2-1 Linux 常用操作命令及其含义

#### 2.3.6 文件解压缩

大数据软件安装包通常都是一个压缩文件,文件名以. tar. gz 为后缀(或者简写为. tgz),这种压缩文件必须经过解压缩以后才能够安装。在 Linux 系统中,可以使用 tar 命令

对后缀名为. tar. gz(或. tgz)的压缩文件进行解压。通常可以采用如下形式的命令:

\$tar - zxf /home/hadoop/下载/hbase-1.1.2-bin.tar.gz - C /usr/local

上面命令表示把"/home/hadoop/下载/hbase-1.1.2-bin.tar.gz"这个文件解压缩后保存到/usr/local 目录下。其中,各个参数的含义如下。

- (1) x:从 tar 包中把文件提取出来。
- (2) z:表示 tar 包是被 gzip 压缩过的,所以解压时需要用 gunzip 解压。
- (3) f:表示后面跟着的是文件。
- (4) C: 表示文件解压后转到指定的目录下。

## 2.3.7 常用的目录

Linux 系统的根目录/下,存在很多个目录,其中有两个目录,是本书学习过程中经常用到的:一个是/home 目录;另一个是/usr 目录。/home 目录包含了各个用户的用户目录,每当在 Linux 系统中新建一个普通用户时,系统就会自动为这个用户创建用户主目录(主文件夹),例如,创建 hadoop 用户时,就会自动创建用户主目录/home/hadoop 及其下面的各个子目录。假设当前采用 hadoop 用户登录了 Linux 系统,这时执行下面命令:

\$cd ~

该命令执行后,就会进入到 hadoop 用户的主文件夹,也就是进入到/home/hadoop目录。

/usr 目录是 UNIX Software Resource 的简写,表示这里是各种软件安装的目录。对于/usr 目录而言,只需要关注它下面的子目录/usr/local,一般由用户安装的软件都建议安装到该目录下,所以,本书所有大数据软件都会被安装到/usr/local 这个目录下。

# 2.3.8 目录的权限

Linux 系统对文件权限有着严格的规定,如果一个用户不具备权限,将无法访问目录及其下面的文件。例如,使用 hadoop 用户登录 Linux 系统以后,从网络上下载了 HBase 安装包文件,把文件解压缩到/usr/local/目录下,会得到一个类似/usr/local/hbase 这样的目录,这时,hadoop 用户并不是/usr/local/hbase 这个目录的所有者,无法对该目录进行相关操作,从而无法正常使用 HBase。这时,就必须采用 chown 命令进行授权,让 hadoop 用户拥有对该目录的权限,具体命令如下:

\$sudo chown -R hadoop /usr/local/hbase

本书安装其他大数据软件,都会涉及类似问题,所以,必须熟练使用该命令。

## 2.3.9 更新 APT

APT 是一款非常优秀的软件管理工具, Linux 系统采用 APT 来安装和管理各种软件。

安装成功 Linux 系统以后,需要及时更新 APT 软件,否则,后续一些软件可能无法正常安装。登录 Linux 系统,打开一个终端(可以使用快捷键 Ctrl+Alt+T),进入 Shell 命令提示符状态,然后输入下面命令:

\$sudo apt-get update

apt-get 命令执行以后,Linux 系统就会开始从网络上下载 APT 的各种更新。若出现 "Hash 校验和不符"的提示(见图 2-54),则可通过更改软件源来解决。若没有该问题,则不 需要更改。另外,从软件源下载某些软件的过程中,可能由于网络方面的原因出现没法下载 的情况,那么建议更改软件源。不过,需要说明的是,在后续安装各种大数据软件过程中,即 使出现"Hash 校验和不符"的提示,一般也不会影响 Hadoop 等软件的正常安装。

```
W: 无法下载 bzip2:/var/lib/apt/lists/partial/cn.archive.ubuntu.com_ubuntu_dists_
trusty-updates_universe_i18n_Translation-en Hash 校验和不符
W: 无法下载 bzip2:/var/lib/apt/lists/partial/cn.archive.ubuntu.com_ubuntu_dists_
trusty-backports_universe_binary-amd64_Packages Hash 校验和不符
```

图 2-54 "校验和不符"的提示信息

如果需要更改软件源,需要在 Linux 系统桌面右上角单击"齿轮"图标,在弹出的菜单中选择单击"系统设置",然后在弹出的界面中单击"软件和更新"图标,会弹出如图 2-55 所示的界面。

❷●□ 软件和	河更新						
Ubuntu软件	其他软件	更新	身份验证	附加驱动			
可从互联网下载							
☑ Canonical 支持的免费和开源软件 (main)							
☑ 社区维护的免费和开源软件 (universe)							
☑ 设备的专有驱动 (restricted)							
✓ 有版权和合法性问题的的软件 (multiverse)							
■ 源代码							
下载自:	中国的服务器    ▼						
可从光驱安装							

图 2-55 "软件和更新"界面

单击"下载自"右侧的下拉列表框,选择"其他节点",会弹出如图 2-56 所示的界面。 在服务器列表中选择 mirrors. aliyun. com,并单击右下角的"选择服务器"按钮,这时,

只要在该界面上单击"关闭"按钮即可,然后,会出现如图 2-58 所示的界面。

需要输入用户密码。最后,会显示如图 2-57 所示的界面。

单击"重新载入"按钮,然后耐心等待更新即可。更新完成后系统会自动关闭"软件和更新"这个窗口。经过上述步骤以后,再去执行 sudo apt-get update 命令,如果这时执行 apt-get 命令还是提示错误,继续按照上面修改软件源的方法,选择其他服务器节点,如mirrors. 163. com,再次进行尝试。更新成功后,再次执行 sudo apt-get update 命令就正常了。



图 2-56 "选择下载服务器"界面



图 2-57 选择服务器相关界面

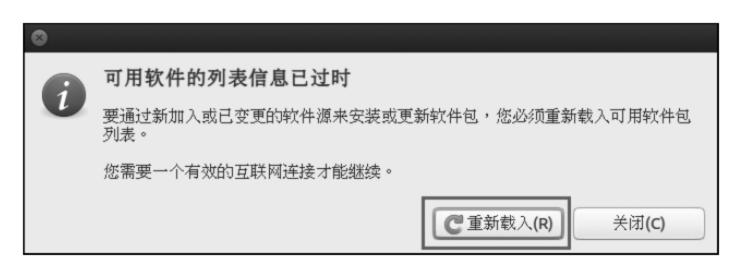


图 2-58 "可用软件的列表信息已过时"提示界面

# 2.3.10 切换中英文输入法

Ubuntu 中终端输入的命令一般都是使用英文输入。但是,有时候也会需要输入中文。 Linux 系统的中英文输入法的切换方式是使用 Shift 键来切换,或者,也可以单击系统桌面 顶部菜单的输入法按钮进行切换。Ubuntu 自带的 Sunpinyin 中文输入法已经可以很好满 足中文输入要求,不需要额外安装中文输入法。

# 2.3.11 vim 编辑器的使用方法

vim 编辑器是 Linux 系统上最著名的文本/代码编辑器,是 vi 编辑器的加强版,可以帮助人们完成文件的创建和代码的编写。登录 Linux 系统(本书全部统一使用 hadoop 用户登

录),打开一个终端,然后,执行下面命令完成 vim 编辑器的安装:

\$sudo apt-get install vim

执行上面命令以后,如果屏幕上出现信息要求进行确认,在提示处输入 y 即可。

下面演示一个实例来了解 vim 编辑器的使用方法。假设要在/home/hadoop/目录下新建一个文件 word. txt,里面包含一些单词。可以执行下面命令创建一个 word. txt 文件:

\$cd ~

\$vim word.txt

通过上面命令就打开了 vim 编辑器,然后,需要键盘敲击输入一个英文字母 i,进入编辑状态以后才能修改内容,这时,就可以向 word. txt 文件中输入一些单词。修改后,需要按键盘上的 Esc 键退出 vim 的编辑状态,之后有以下几种选择。

- (1) 从键盘输入":wq"3个英文字符,然后按 Enter 键,表示保存文件并退出。
- (2) 从键盘输入":q"两个英文字符,然后按 Enter 键,表示不保存并退出。如果本次编辑过程只是查看了文件内容,没有对文件做任何修改,则可以顺利退出。但是,如果已经修改了文件内容,则 vim 编辑器不允许就这样退出,会给出提示信息,这时,要想不保存就退出 vim 编辑器,就要采用下面一种方式,即输入":q!"。
  - (3) 从键盘输入":q!"3个英文字符,然后按 Enter 键,表示不保存并强制退出。

这里我们从键盘输入":wq"3个英文字符,然后按 Enter 键,表示保存文件并退出 vim 编辑器。这样,就成功创建了 word. txt 文件,这时使用 ls 命令查看,就会发现/home/hadoop/目录下多了一个 word. txt 文件。如果要查看 word. txt 文件中的内容,可以采用两种方式:第一种方式是,仍然使用 vim 编辑器打开 word. txt 文件,查看其内容;第二种方式是使用 cat 命令,这种方式要比前一种简单得多。

这里需要指出的是,在Linux系统中使用 vim 编辑器创建一个文件时,并不是以扩展名来区分文件的,不管是否有扩展名,都是生成文本文件,txt 扩展名只是我们自己人为添加,方便自己查看用的。也就是说,创建 word. txt 和 word 这两个文件,对于 Linux 系统而言都是默认创建了文本类型的文件,和是否有 txt 扩展名没有关系。

# 2.3.12 在 Windows 系统中使用 SSH 方式登录 Linux 系统

当采用虚拟机安装方式时,Linux 虚拟机就像运行在 Windows 上的一个软件。这时,在使用 Linux 系统时,可以随时把 VirtualBox 窗口最小化,返回到 Windows 桌面,继续使用 Windows 系统,然后需要用 Linux 系统时,再切换到 VirtualBox 窗口即可。

由于 Windows 系统运行和使用各种软件的体验都会比较流畅,例如浏览网页搜索大数据资料等,相对而言,在 Linux 中使用各种软件,体验会比 Windows 差很多。所以,我们通常都习惯在 Windows 系统中使用浏览器去搜索阅读相关资料,如代码实例等。想象一下我们可能会遇到下面这种场景,在 Linux 系统中使用 vim 编辑器打开了一个 testInLinux. txt 文件,在 Windows 系统中通过网络搜索找到了一段实例代码,这时,我们很想把 Windows 系统中的网页里面的代码复制并粘贴到 Linux 系统中的正在被 vim 编辑器打开的

testInLinux. txt 文件中。

在 Windows 系统内部,在两个文本文件 A 和 B 之间复制、粘贴内容,通常是借助于"剪贴板"的功能。剪贴板是 Windows 操作系统在内存中设置的一块区域,用于数据共享。在 Windows 系统中,选中文件 A 中的内容,右击,在弹出菜单中单击"复制"选项,内容就被复制到剪贴板中暂时保存,然后,在文件 B 中,单击"粘贴"选项,就把内容从剪贴板粘贴到文件 B 中了。

所以,一个很自然的想法是,在 Windows 系统的浏览器中,复制这段实例代码到剪贴板中,然后,再切换到 Linux 虚拟机界面,把代码粘贴到正在被 vim 编辑器打开的 testinlinux. txt 文件中。遗憾的是,这样做会失败,系统是不支持直接把 Windows 系统中的内容直接复制、粘贴到 Linux 系统中的,因为,Windows 系统和 Linux 系统是完全独立的两个系统,在默认情况下,Windows 系统中的剪贴板对于 Linux 系统而言,是不可见的。所以,在Windows 系统中把代码复制到剪贴板上以后,只能在 Windows 系统中执行粘贴操作,无法在 Linux 中执行粘贴操作。

那么,怎么才能把 Windows 中的代码直接粘贴到 Linux 系统的文件中呢? VirtualBox 等虚拟机软件提供了可以让 Windows 和 Linux 两个系统共享剪贴板的功能,如图 2-59 所示。



图 2-59 在 VirtualBox 界面中设置共享剪贴板

在图 2-59 中,只要把共享剪贴板设置为"双向",就可以在 Windows 和 Linux 系统之间互相复制、粘贴文本内容。但是,需要说明的是,在实际应用过程中,对于一些计算机而言,这个功能可能会失效,所以,下面介绍另外一种方法实现在两个操作系统之间复制、粘贴文本。

前面介绍过的 FTP 软件,只能进行整个文件的传输,即把整个文件从 Windows 系统传输到 Linux 系统中,而无法把某段代码直接粘贴到 Linux 系统的文件中。因此,我们需要采用在 Windows 系统中使用 SSH 方式登录 Linux 系统,实现文本内容(如代码)的复制、粘贴;当然,SSH 方式也可以用来实现远程登录,例如,在宿舍用 SSH 方式远程登录位于实验室的某台 Linux 服务器。

本书采用 PuTTY 软件实现 SSH 登录到 Linux 系统。PuTTY 是一个免费的、Windows x86 平台下的 Telnet、SSH 和 rlogin 客户端,也是目前较为流行的远程登录工具之一。在 Windows 系统中访问本书官网下载该软件,位于"下载专区"的"软件"目录下,文件名是 putty\_V0.63.0.0.43510830.exe。下载后,保存到 Windows 系统下,然后在 Windows 系统中启动 PuTTY,会出现如图 2-60 所示的设置界面。

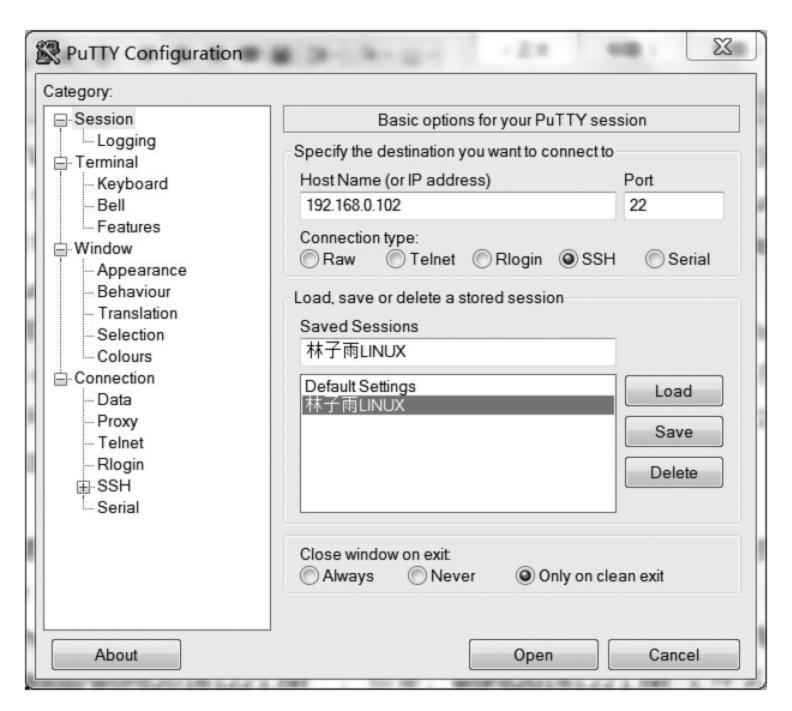


图 2-60 PuTTY 设置界面

在设置界面中,在 Host Name(or IP address)下面的文本框中填入 Linux 虚拟机的 IP 地址,前面在介绍 FTP 软件使用方法时已经介绍过 IP 地址的查询方法,请参考前面的方法,在 Linux 终端中使用 ifconfig 命令查询得到 Linux 虚拟机的 IP 地址。在 Port 下面的文本框中填入端口号 22。在 Connection type 下面的选择按钮中,选中 SSH 作为登录方式。在 Close window on exit 下面选择 Only on clean exit。最后可以单击 Save 按钮保存当前设置,建议给当前连接起一个名称,以便下次重复使用(下次再用时,只要选中该连接名称,然后单击 Load 按钮,就可以把之前保存好的配置信息自动加载进来)。

此外,默认设置情况下,连接成功后,字体会比较小,容易产生视觉疲劳,可以事先对字体大小进行设置。在设置界面的左侧,单击 Windows 下面的 Appearance 子目录,进入外观的设置界面(见图 2-61)。

在该界面中,单击 Font settings 右侧的 Change 按钮,在弹出的界面中,选择合适的字体大小,例如,设置为 18,然后单击"确定"按钮,最后单击 Open 按钮,就启动 SSH 登录了。这时可能会弹出一个英文界面,只要单击 OK 按钮确定就可以继续登录,登录后的界面如图 2-62 所示。

需要在"login as:"后面输入登录 Linux 系统的用户名,这里使用用户名 hadoop,然后,输入 hadoop 用户的密码(密码也是 hadoop),验证通过后,就进入 Linux 的 Shell 命令提示符状态了,就相当于之前在 Linux 系统中打开的终端一样,可以在里面输入各种 Linux 命令。如果要退出登录,可以输入 exit 命令,就会退出并关闭 PuTTY 窗口。

假设目前已经使用 PuTTY 软件从 Windows 系统中登录到了 Linux 系统中,这时,就可以完成代码的复制、粘贴了。因为,这个时候,PuTTY 只是运行在 Windows 系统中的一

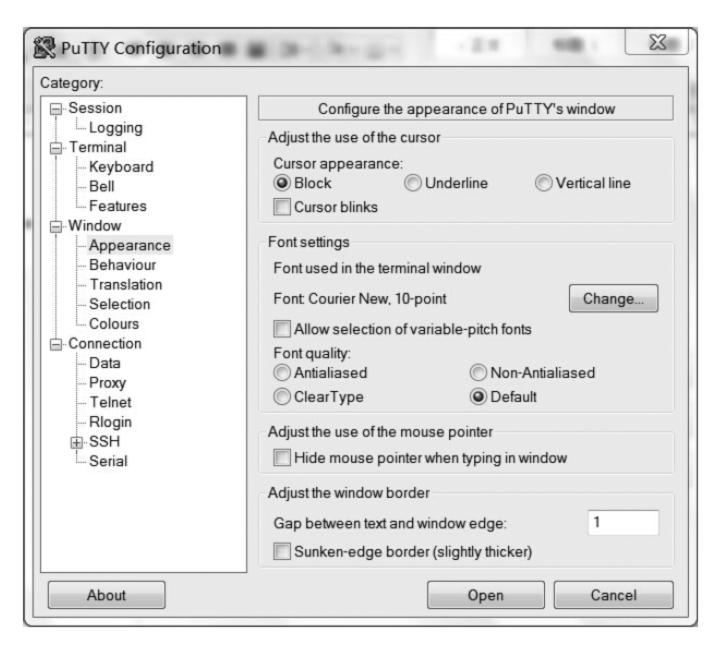


图 2-61 PuTTY 配置外观界面

```
login as: hadoop
hadoop@dblab-VirtualBox~
login as: hadoop
hadoop@192.168.0.102's password:
Welcome to Ubuntu 16.04 LTS (GNU/Linux 4.4.0-57-generic x86_64)

* Documentation: https://help.ubuntu.com/

325 个可升级软件包。
4 个安全更新。

Last login: Thu Dec 22 08:28:13 2016 from 192.168.0.101
hadoop@dblab-VirtualBox:~$
```

图 2-62 PuTTY 登录界面

个软件,是可以看到 Windows 系统中的剪贴板的。在 PuTTY 中使用 vim 编辑器,新建一个文本文件 testInLinux. txt,然后,执行两个小实验。

首先,测试从 Windows 系统中复制一段代码,粘贴到 Linux 系统的 testInLinux. txt 文件中。可以在 Windows 系统中打开浏览器,在网络上找到一段代码,通过"复制"命令,把代码复制到 Windows 的剪贴板上。接下来,把窗口切换到 PuTTY 窗口,在打开的 vim 编辑器中右击,就可以把代码粘贴到 testInLinux. txt 文件中,然后保存并退出 vim 编辑器。也就是说,在 PuTTY 窗口中操作 Linux 系统时右击,就表示"粘贴",会把刚才复制的内容粘贴进去。不仅可以粘贴到 vim 编辑器中去,也可以粘贴到 Shell 命令提示符后面。

其次,测试从 Linux 系统中复制一段代码,粘贴到 Windows 系统中的文本文件中。例如,现在需要把 Linux 系统中的 testInLinux. txt 的部分代码复制到 Windows 系统中的 testInWindows. txt 中。在 PuTTY 窗口中,使用 vim 编辑器打开 testInLinux. txt,然后用 鼠标左键选中需要复制的代码。注意,只要选中即可,选中被复制的代码以后,这些代码自 动就被保存到了 Windows 的剪贴板上。然后到 Windows 系统中打开的 testInWindows.

txt 中,执行粘贴操作(如用快捷键 Ctrl+V),就可以把代码粘贴到 testInWindows. txt 中。同理,如果需要把 PuTTY 窗口中一些命令执行后在屏幕上显示的信息复制、粘贴到 Windows 中,也可以这么操作。例如,有时候,人们在 PuTTY 窗口中执行某条命令,屏幕上返回了错误信息,人们需要在 Windows 系统的浏览器中去网络搜索错误的解决方案,这时,就可以在 PuTTY 窗口中,用鼠标左键选中错误信息,然后把这些错误信息粘贴到 Windows 下的搜索引擎页面中,就可以获得很好的网页浏览体验了,毕竟在 Linux 系统中使用浏览器的体验不是很好。

## 2.3.13 在 Linux 中安装 Eclipse

Eclipse 是常用的程序开发工具,可以利用 Ubuntu 自带的"软件中心"安装 Eclipse 等各种软件。"Ubuntu 软件中心"快捷图标如图 2-63 所示。



图 2-63 桌面上的快速启动栏

进入"Ubuntu 软件中心"以后,在界面右上角的搜索框中输入 Eclipse,会自动出现 Eclipse 软件安装快捷按钮(见图 2-64)。

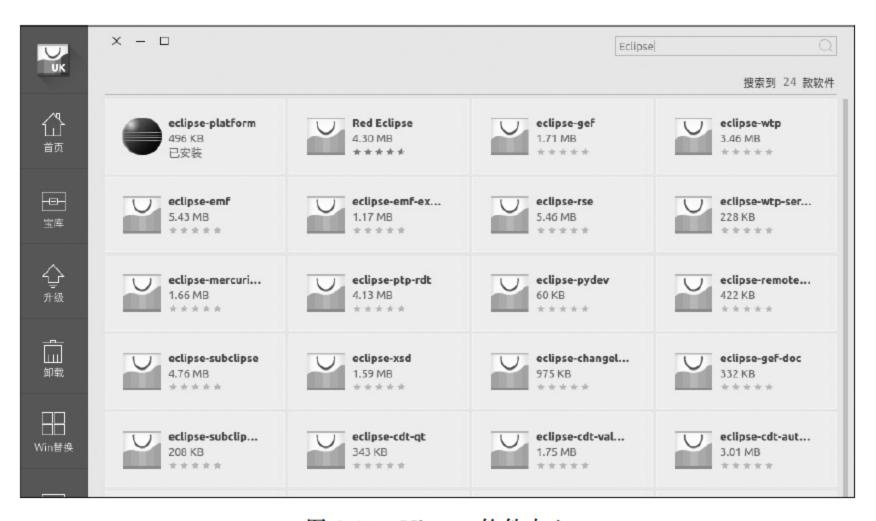


图 2-64 Ubuntu 软件中心

单击"安装"按钮就可以顺利完成 Eclipse 的安装。安装时需要管理员权限, Ubuntu 系统会弹出"认证"窗口进行用户认证,请输入当前用户的登录密码。同时需要注意的是,安装过程需要从网络下载相关文件,所以,要保持计算机一直处于联网状态。

Eclipse 安装完成以后,可以单击桌面快捷启动图标栏中的"资源搜索"图标(见图 2-63 中最左侧的图标)。在弹出的"资源搜索"界面中,可以在界面左上角的搜索框中输入 Eclipse,就可以找到刚才已经安装好的 Eclipse 软件(见图 2-65),单击 Eclipse 图标,就可以

启动运行 Eclipse 软件。



图 2-65 资源搜索界面

## 2.3.14 其他使用技巧

#### 1. 使用 Tab 键自动补全命令

在 Linux Shell 中输入命令时,可以使用快捷键 Tab 自动补全命令,节省输入时间。例如,要使用 vim 编辑器打开文件/home/hadoop/word20161221.txt,正常情况下,需要输入 vim /home/hadoop/word20161221.txt,但是,word20161221.txt 文件名不好记忆,手动输入也容易出错,所以,可以采用 Linux 自动补全功能简化输入工作。具体方法是,输入 vim /home/hadoop/word 以后,就不要继续输入后面的 20161221.txt,而是直接按一下键盘上的 Tab 键,Linux 系统就会自动补上 20161221.txt。

#### 2. 隐藏文件

在 Linux 下,以英文点号"."开头命名的文件,在系统中被视为隐藏文件。因此,如果想隐藏某个文件或目录,一种简单的办法就是把文件名命名为以英文点号开头。例如,后面学习过程中经常用到的. bashrc 文件,就是一个隐藏文件,用来保存系统的各种环境变量。

#### 3. 重现历史命令

在 Linux 的终端中,人们会输入大量命令,系统会自动保存人们历史上输入的命令,可以按键盘上的"上箭头"和"下箭头"按钮,翻看历史命令,找到某条历史命令后,可以直接按 Enter 键执行该命令,这样,就不需要重复输入一些较长的命令了,大幅节省了命令输入时间。

# 2.4 关于本书内容的一些约定

为了准确理解本书后续的内容,这里对本书的内容做如下约定。

- (1) 本书全部采用 hadoop 用户登录 Linux 系统。
- (2) 本书所有在 Linux 系统中下载的文件都保存到"/home/hadoop/下载/"目录下,所有从 Windows 系统中通过 FTP 软件上传到 Linux 系统中的文件,也放在"/home/hadoop/下载/"目录下,总之,这个目录就是本书选择的 Linux 系统中的文件中转站。
- (3) 本书中,当需要在 Linux 系统的"终端"中输入命令时,全部统一采用如下格式,即 \$符号开头,后面跟上 Linux 命令:

\$cd /usr/local #设置当前目录

在上面命令中, #表示注释。所以, 后面内容中只要是\$开始的命令, 都在 Linux 系统中打开一个终端, 进入 Shell 命令提示符状态后执行命令。

- (4)由于页面的宽度限制,当一行命令过长时,排版时会被放到下一行,例如,下面的命令虽然包含两行,实际上是一行完整的命令。
  - \$ ./bin/hadoop jar ./share/hadoop/mapreduce/hadoop- mapreduce- examples- \* .jar grep ./input
    ./output 'dfs[a-z.]+ '

# 2.5 本章小结

本书几乎所有软件(除了可视化工具 Tableau 以外)都是安装和运行在 Linux 操作系统之上,因此,顺利安装好 Linux 系统并且掌握 Linux 系统的基本使用方法,是开展后续章节内容学习的前提和基础。

Linux 系统可以采用双系统方式安装,也可以采用虚拟机方式安装,建议在大数据初学阶段采用虚拟机方式安装。本章详细介绍了如何安装 Linux 虚拟机,并给出了生成 Linux 虚拟机镜像文件的方法,可以实现 Linux 虚拟机的快速复制安装。另外,为了帮助读者更好地开展 Linux 系统下的相关操作和实践,本章简要介绍了 Linux 系统及其相关软件的基本使用方法。最后,本章给出了关于本书的一些约定,了解这些约定,有助于准确理解后续章节的内容。

# 第3章

# Hadoop 的安装和使用

Hadoop 是一个开源的、可运行于大规模集群上的分布式计算平台,它主要包含分布式并行编程模型 MapReduce 和分布式文件系统 HDFS 等功能,已经在业内得到广泛的应用。借助于 Hadoop,程序员可以轻松地编写分布式并行程序,将其运行于计算机集群上,完成海量数据的存储与处理分析。

本章首先简要介绍 Hadoop 的发展情况;然后,阐述安装 Hadoop 之前的一些必要准备工作;最后,介绍安装 Hadoop 的具体方法,包括单机模式、伪分布式模式、分布式模式以及使用 Docker 搭建 Hadoop 集群。

# 3.1 Hadoop 简介

Hadoop 是 Apache 软件基金会旗下的一个开源分布式计算平台,为用户提供了系统底层细节透明的分布式基础架构。Hadoop 是基于 Java 语言开发的,具有很好的跨平台特性,并且可以部署在廉价的计算机集群中。Hadoop 的核心是分布式文件系统(Hadoop Distributed File System, HDFS)和 MapReduce。

Hadoop 被公认为行业大数据标准开源软件,在分布式环境下提供了海量数据的处理能力。几乎所有主流厂商都围绕 Hadoop 提供开发工具、开源软件、商业化工具和技术服务,如谷歌、微软、思科、淘宝等,都支持 Hadoop。

Apache Hadoop 版本分为两代:第一代 Hadoop 称为 Hadoop 1.0;第二代 Hadoop 称为 Hadoop 2.0。第一代 Hadoop 包含 0.20.x、0.21.x 和 0.22.x 三大版本,其中,0.20.x 最后演化成 1.0.x,变成了稳定版,而 0.21.x 和 0.22.x 则增加了 HDFS HA 等重要的新特性。第二代 Hadoop 包含 0.23.x 和 2.x 两大版本,它们完全不同于 Hadoop 1.0,是一套全新的架构,均包含 HDFS Federation 和 YARN(Yet Another Resource Negotiator)两个组件。本书采用 Hadoop 2.7.1 版本。

除了免费开源的 Apache Hadoop 以外,还有一些商业公司推出的 Hadoop 发行版。2008年,Cloudera 成为第一个 Hadoop 商业化公司,并在 2009年推出第一个 Hadoop 发行版。此后,很多大公司也加入了做 Hadoop 产品化的行列,如 MapR、Hortonworks、星环等。一般而言,商业化公司推出的 Hadoop 发行版,也是以 Apache Hadoop 为基础,但是,前者比后者具有更好的易用性、更多的功能和更高的性能。

# 3.2 安装 Hadoop 前的准备工作

本节介绍安装 Hadoop 之前的一些准备工作,包括创建 hadoop 用户、更新 APT、安装 SSH 和安装 Java 环境等。

# 3.2.1 创建 hadoop 用户

本书全部采用 hadoop 用户登录 Linux 系统,并为 hadoop 用户增加了管理员权限。在第2章中已经介绍了 hadoop 用户创建和增加权限的方法,一定要按照该方法创建 hadoop 用户,并且使用 hadoop 用户登录 Linux 系统,然后再开始下面的学习内容。

## 3.2.2 更新 APT

第2章介绍了APT软件作用和更新方法,为了确保 Hadoop 安装过程顺利进行,建议按照第2章介绍的方法,用 hadoop 用户登录 Linux 系统后打开一个终端,执行下面命令更新 APT 软件:

\$sudo apt-get update

# 3.2.3 安装 SSH

SSH 是 Secure Shell 的缩写,是建立在应用层和传输层基础上的安全协议。SSH 是目前较可靠、专为远程登录会话和其他网络服务提供安全性的协议。利用 SSH 协议可以有效防止远程管理过程中的信息泄露问题。SSH 最初是 UNIX 系统上的一个程序,后来又迅速扩展到其他操作平台。SSH 是由客户端和服务端的软件组成,服务端是一个守护进程,它在后台运行并响应来自客户端的连接请求,客户端包含 ssh 程序以及像 scp(远程复制)、slogin(远程登录)、sftp(安全文件传输)等其他的应用程序。

为什么在安装 Hadoop 之前要配置 SSH 呢?这是因为, Hadoop 名称节点(NameNode)需要启动集群中所有机器的 Hadoop 守护进程,这个过程需要通过 SSH 登录来实现。Hadoop 并没有提供 SSH 输入密码登录的形式,因此,为了能够顺利登录集群中的每台机器,需要将所有机器配置为"名称节点可以无密码登录它们"。

Ubuntu 默认已安装了 SSH 客户端,因此,这里还需要安装 SSH 服务端,在 Linux 的终端中执行以下命令:

\$sudo apt-get install openssh-server

安装后,可以使用如下命令登录本机:

\$ssh localhost

执行该命令后会出现如图 3-1 所示的提示信息(SSH 首次登录提示),输入 yes,然后按

提示输入密码 hadoop,就登录到本机了。

```
hadoop@DBLab-XMU:~$ ssh localhost
The authenticity of host 'localhost (127.0.0.1)' can't be established.
ECDSA key fingerprint is a9:28:e0:4e:89:40:a4:cd:75:8f:0b:8b:57:79:67:86.
Are you sure you want to continue connecting (yes/no)? yes
```

图 3-1 SSH 登录提示信息

这里在理解上会有一点"绕弯"。也就是说,原本我们登录进入 Linux 系统以后,就是在本机上,这时,在终端中输入的每条命令都是直接提交给本机去执行,然后,又在本机上使用 SSH 方式登录到本机,这时,在终端中输入的命令,是通过 SSH 方式提交给本机处理。如果换成包含两台独立计算机的场景,SSH 登录会更容易理解。例如,有两台计算机 A 和 B 都安装了 Linux 系统,计算机 B 上安装了 SSH 服务端,计算机 A 上安装了 SSH 客户端,计算机 B 的 IP 地址是 59.77.16.33,在计算机 A 上执行命令 ssh 59.77.16.33,就实现了通过 SSH 方式登录计算机 B 上面的 Linux 系统,在计算机 A 的 Linux 终端中输入的命令,都会提交给计算机 B 上的 Linux 系统执行,也就是说,在计算机 A 上操作计算机 B 中的 Linux 系统。现在,只有一台计算机,就相当于计算机 A 和 B 都在同一台机器上,所以,理解起来就会有点"绕弯"。

由于这样登录需要每次输入密码,所以,需要配置成 SSH 无密码登录会比较方便。在 Hadoop 集群中,名称节点要登录某台机器(数据节点)时,也不可能人工输入密码,所以,也 需要设置成 SSH 无密码登录。

首先输入命令 exit 退出刚才的 SSH,就回到了原先的终端窗口;然后可以利用 ssh-keygen 生成密钥,并将密钥加入到授权中,命令如下:

```
$cd ~/.ssh/ #若没有该目录,请先执行一次 ssh localhost
$ssh-keygen - t rsa #会有提示,按 Enter键即可
$cat ./id_rsa.pub >> ./authorized_keys #加入授权
```

此时,再执行 ssh localhost 命令,无须输入密码就可以直接登录了,如图 3-2 所示。

```
hadoop@DBLab-XMU:~/.ssh$ ssh localhost
Welcome to Ubuntu 14.04.2 LTS (GNU/Linux 3.13.0-49-generic x86_64)

* Documentation: https://help.ubuntu.com/

40 packages can be updated.
40 updates are security updates.

Last login: Thu Apr 30 21:20:50 2015 from localhost
hadoop@DBLab-XMU:~$
```

图 3-2 SSH 登录后的提示信息

# 3.2.4 安装 Java 环境

Hadoop 是基于 Java 语言开发的,本书的 Hadoop 应用程序也是采用 Java 语言编写的,因此,需要安装 Java 环境。Java 环境可选择安装 Oracle 的 JDK,或者安装 OpenJDK。下面介绍两种不同的安装方式,优先选择第一种方式,如果第一种方式失败,请选择第二种方式。

#### 1. 第一种安装方式

直接通过如下命令安装 OpenJDK 7:

\$sudo apt-get install openjdk-7-jre openjdk-7-jdk

上述安装过程需要访问网络下载相关文件,请保持联网状态。安装好 OpenJDK 后,需要找到相应的安装路径,这个路径是用于配置 JAVA\_HOME 环境变量的,请执行如下命令:

\$dpkg - L openjdk - 7 - jdk | grep '/bin/javac'

该命令会输出一个路径,除去路径末尾的/bin/javac,剩下的就是正确的路径了。例如, 上面的命令执行后输出路径为/usr/lib/jvm/java-7-openjdk-amd64/bin/javac,则我们需要 的路径为/usr/lib/jvm/java-7-openjdk-amd64。

接下来需要配置 JAVA\_HOME 环境变量,为方便起见,这里直接在~/. bashrc 这个文件中进行设置,采用这种配置方式时,只对当前登录的单个用户生效,当该用户登录以及每次打开新的 Shell 时,它的环境变量文件. bashrc 会被读取。在 Linux 终端中输入下面命令打开当前登录用户的环境变量配置文件. bashrc:

\$vim ~/.bashrc

在文件最前面添加如下单独一行(注意,等号(=)前后不能有空格),然后保存退出:

export JAVA HOME=/usr/lib/jvm/java-7-openjdk-amd64

接下来要让环境变量立即生效,执行如下代码

\$source ~/.bashrc #使变量设置生效

执行上述命令后,可以检验一下是否设置正确:

\$echo \$JAVA HOME

#检验变量值

\$java - version

\$\$JAVA HOME/bin/java - version

#与直接执行 java - version 一样

如果设置正确,\$JAVA\_HOME/bin/java-version 命令执行后,会输出 Java 的版本信息,并且和 java-version 的输出结果一样。

至此, Hadoop 所需的 Java 运行环境就顺利安装完成。

#### 2. 第二种安装方式

根据大量计算机安装 Java 环境的情况发现,部分计算机按照上述的第一种安装方式会

出现安装失败的情况,这时,可以采用这里介绍的另外一种安装方式,命令如下:

\$sudo apt-get install default-jre default-jdk

上述安装过程需要访问网络下载相关文件,请保持联网状态。安装结束以后,需要配置 JAVA\_HOME 环境变量,在 Linux 终端中输入下面命令打开当前登录用户的环境变量配 置文件. bashrc:

\$vim ~/.bashrc

在文件最前面添加如下单独一行(注意,等号(=)前后不能有空格),然后保存退出:

export JAVA\_HOME=/usr/lib/jvm/default-java

接下来要让环境变量立即生效,执行如下代码:

\$source ~/.bashrc

#使变量设置生效

执行上述命令后,可以检验一下是否设置正确:

\$echo \$JAVA HOME

#检验变量值

\$java - version

\$\$JAVA\_HOME/bin/java - version #与直接执行 java - version 一样

至此,就成功安装了Java 环境。下面就可以进入 Hadoop 的安装。

# 3.3 安装 Hadoop

Hadoop 包括 3 种安装模式。

- (1) 单机模式。只在一台机器上运行,存储采用本地文件系统,没有采用分布式文件系 统 HDFS。
- (2) 伪分布式模式。存储采用分布式文件系统 HDFS,但是,HDFS 的名称节点和数据 节点都在同一台机器上。
- (3) 分布式模式。存储采用分布式文件系统 HDFS,而且,HDFS 的名称节点和数据节 点位于不同机器上。

本节介绍 Hadoop 的具体安装方法,包括下载安装文件、单机模式配置、伪分布式模式 配置、分布式模式配置和使用 Docker 搭建 Hadoop 分布式集群等。

#### 下载安装文件 3.3.1

本书采用的 Hadoop 版本是 2.7.1,可以到 Hadoop 官网下载安装文件(http:// mirrors. cnnic. cn/apache/hadoop/common/),或者也可以到本书官网的"下载专区"中下载

安装文件,进入下载专区后,在"软件"这个文件夹中,找到文件 hadoop-2.7.1. tar. gz,下载到本地。下载的方法是,在 Linux 系统中(不是在 Windows 系统中),打开浏览器,一般自带了火狐(FireFox)浏览器。打开浏览器后,访问本书官网,下载 hadoop-2.7.1. tar. gz。火狐浏览器默认会把下载文件都保存到当前用户的下载目录,由于本书全部采用 hadoop 用户登录 Linux 系统,所以,hadoop-2.7.1. tar. gz 文件会被保存到"/home/hadoop/下载/"目录下。

需要注意的是,如果是在 Windows 系统下面下载安装文件 hadoop-2.7.1. tar. gz,则需要通过 FTP 软件上传到 Linux 系统的"/home/hadoop/下载/"目录下,这个目录是本书所有安装文件的中转站。

下载完安装文件以后,需要对文件进行解压。按照 Linux 系统使用的默认规范,用户安装的软件一般都是存放在/usr/local/目录下。使用 hadoop 用户登录 Linux 系统,打开一个终端,执行如下命令:

\$sudo tar - zxf ~/下载/hadoop-2.7.1.tar.gz - C /usr/local

#解压到/usr/local 目录中

\$cd /usr/local/

\$sudo mv ./hadoop-2.7.1/ ./hadoop

#将文件夹名改为 hadoop

\$sudo chown - R hadoop ./hadoop

#修改文件权限

Hadoop 解压后即可使用,可以输入如下命令来检查 Hadoop 是否可用,成功则会显示 Hadoop 版本信息:

\$cd /usr/local/hadoop

\$./bin/hadoop version

# 3.3.2 单机模式配置

Hadoop 的默认模式为非分布式模式(本地模式),无须进行其他配置即可运行。 Hadoop 附带了丰富的例子,运行如下命令可以查看所有例子:

\$cd /usr/local/hadoop

\$./bin/hadoop jar ./share/hadoop/mapreduce/hadoop-mapreduce-examples-2.7.1.jar

上述命令执行后,会显示所有例子的简介信息,包括 grep、join、wordcount 等。这里选择运行 grep 例子,可以先在/usr/local/hadoop 目录下创建一个文件夹 input,并复制一些文件到该文件夹下;然后,运行 grep 程序,将 input 文件夹中的所有文件作为 grep 的输入,让 grep 程序从所有文件中筛选出符合正则表达式"dfs[a-z.]+"的单词,并统计单词出现的次数,最后,把统计结果输出到/usr/local/hadoop/output 文件夹中。完成上述操作的具体命令如下:

\$cd /usr/local/hadoop

\$mkdir input

\$cp ./etc/hadoop/\* .xml ./input #将配置文件复制到 input 目录下

```
$./bin/hadoop jar ./share/hadoop/mapreduce/hadoop-mapreduce-examples-*.
jar grep ./input ./output 'dfs[a-z.]+'
$cat ./output/* #查看运行结果
```

执行成功后结果如图 3-3 所示,输出了作业的相关信息,输出的结果是符合正则表达式的单词 dfsadmin 出现了 1 次。



图 3-3 grep 程序运行结果

需要注意的是, Hadoop 默认不会覆盖结果文件, 因此, 再次运行上面实例会提示出错。如果要再次运行, 需要先使用如下命令把 output 文件夹删除:

```
$rm - r ./output
```

## 3.3.3 伪分布式模式配置

Hadoop 可以在单个节点(一台机器)上以伪分布式的方式运行,同一个节点既作为名称节点(Name Node),也作为数据节点(Data Node),读取的是分布式文件系统 HDFS 中的文件。

#### 1. 修改配置文件

需要配置相关文件,才能够让 Hadoop 在伪分布式模式下顺利运行。Hadoop 的配置文件位于/usr/local/hadoop/etc/hadoop/中,进行伪分布式模式配置时,需要修改 2 个配置文件,即 core-site. xml 和 hdfs-site. xml。

可以使用 vim 编辑器打开 core-site. xml 文件,它的初始内容如下:

```
<configuration>
```

修改以后, core-site. xml 文件的内容如下:

在上面的配置文件中,hadoop. tmp. dir 用于保存临时文件,若没有配置 hadoop. tmp. dir 这个参数,则默认使用的临时目录为/tmp/hadoo-hadoop,而这个目录在 Hadoop 重启时有可能被系统清理掉,导致一些意想不到的问题,因此,必须配置这个参数。fs. defaultFS 这个参数,用于指定 HDFS 的访问地址,其中,9000 是端口号。

同样,需要修改配置文件 hdfs-site. xml,修改后的内容如下:

在 hdfs-site. xml 文件中,dfs. replication 这个参数用于指定副本的数量,因为,在分布式文件系统 HDFS中,数据会被冗余存储多份,以保证可靠性和可用性。但是,由于这里采用伪分布式模式,只有一个节点,所以,只可能有 1 个副本,所以,设置 dfs. replication 的值为 1。dfs. namenode. name. dir 用于设定名称节点的元数据的保存目录,dfs. datanode. data. dir 用于设定数据节点的数据保存目录,这两个参数必须设定,否则后面会出错。

配置文件 core-site. xml 和 hdfs-site. xml 的内容,也可以直接到本书官网的"下载专区"下载,位于"代码"目录下的"第 3 章"子目录下的"伪分布式模式配置"子目录中。

需要指出的是,Hadoop 的运行方式(如运行在单机模式下还是运行在伪分布式模式下)是由配置文件决定的,启动 Hadoop 时会读取配置文件,然后根据配置文件来决定运行在什么模式下。因此,如果需要从伪分布式模式切换回单机模式,只需要删除 core-site.xml 中的配置项即可。

#### 2. 执行名称节点格式化

修改配置文件以后,要执行名称节点的格式化,命令如下:

```
$cd /usr/local/hadoop
$./bin/hdfs namenode - format
```

如果格式化成功,会看到 has been successfully formatted 和 Exiting with status 0 的提示信息(见图 3-4),若为 Exiting with status 1,则表示出现错误。

图 3-4 执行名称节点格式化后的提示信息

如果在执行这一步时提示错误信息"Error: JAVA\_HOME is not set and could not be found",则说明之前设置 JAVA\_HOME 环境变量时,没有设置成功,要按前面的内容介绍先设置好 JAVA\_HOME 变量,否则,后面的过程都无法顺利进行。

### 3. 启动 Hadoop

执行下面命令启动 Hadoop:

```
$cd /usr/local/hadoop
$./sbin/start-dfs.sh #start-dfs.sh是一个完整的可执行文件,中间没有空格
```

如果出现如图 3-5 所示的 SSH 提示,输入 yes 即可:

```
hadoop@DBLab-XMU:/usr/local/hadoop$ sbin/start-dfs.sh
Starting namenodes on [localhost]
localhost: starting namenode, logging to /usr/local/hadoop/logs/hadoop-hadoop-na
localhost: starting datanode, logging to /usr/local/hadoop/logs/hadoop-hadoop-da
Starting secondary namenodes [0.0.0.0]
The authenticity of host '0.0.0.0 (0.0.0.0)' can't be established.

ECDSA key fingerprint is a9:28:e0:4e:89:40:a4:cd:75:8f:0b:8b:57:79:67:86.

Are you sure you want to continue connecting (yes/no)? yes
```

图 3-5 启动 Hadoop 后的提示信息

启动时可能会出现如下警告信息:

```
WARN util.NativeCodeLoader: Unable to load native-hadoop library for your platform. using builtin-java classes where applicable WARN
```

这个警告提示信息可以忽略,并不会影响 Hadoop 正常使用。

如果启动 Hadoop 时遇到输出非常多"ssh: Could not resolve hostname xxx"的异常情况,如图 3-6 所示。

这并不是 SSH 的问题,可以通过设置 Hadoop 环境变量来解决。首先,按 Ctrl+C 键

```
library: ssh: Could not resolve hostname library: Name or service not known which: ssh: Could not resolve hostname which: Name or service not known disabled: ssh: Could not resolve hostname disabled: Name or service not known warning:: ssh: Could not resolve hostname warning:: Name or service not known stack: ssh: Could not resolve hostname stack: Name or service not known
```

图 3-6 Hadoop 启动后的错误提示信息

中断启动过程;然后,使用 vim 编辑器打开文件 $\sim$ /. bashrc,在文件最上边的开始位置增加如下两行内容(设置过程与 JAVA\_HOME 变量一样,其中,HADOOP\_HOME 为 Hadoop的安装目录):

```
export HADOOP_HOME=/usr/local/hadoop
export HADOOP_COMMON_LIB_NATIVE_DIR=$HADOOP_HOME/lib/native
```

保存该文件以后,务必要执行命令 source ~/. bashrc 使变量设置生效;然后,再次执行命令./sbin/start-dfs. sh 启动 Hadoop。

Hadoop 启动完成后,可以通过命令 jps 来判断是否成功启动,命令如下:

```
$jps
```

若成功启动,则会列出如下进程: NameNode、DataNode 和 SecondaryNameNode。如果看不到 SecondaryNameNode 进程,运行命令./sbin/stop-dfs. sh 关闭 Hadoop 相关进程;然后再次尝试启动。如果看不到 NameNode 或 DataNode 进程,则表示配置不成功,仔细检查之前的步骤,或通过查看启动日志排查原因。

通过 start-dfs. sh 命令启动 Hadoop 以后,就可以运行 MapReduce 程序处理数据,此时是对 HDFS 进行数据读写,而不是对本地文件进行读写。

### 4. Hadoop 无法正常启动的解决方法

一般可以通过查看启动日志来排查原因。启动时屏幕上会显示类似如下信息:

```
DBLab-XMU: starting namenode, logging to /usr/local/hadoop/logs/hadoop-hadoop-namenode-DBLab-XMU.out
```

其中,DBLab-XMU对应的是机器名(你的机器名可能不是这个名称),不过,实际上启动日志信息记录在下面这个文件中:

```
/usr/local/hadoop/logs/hadoop-hadoop-namenode-DBLab-XMU.log
```

所以,应该查看这个后缀为. log 的文件,而不是. out 文件。此外,每一次的启动日志都是追加在日志文件之后,所以,需要拉到日志文件的最后面查看,根据日志记录的时间信息,

就可以找到某次启动的日志信息。

当找到属于本次启动的一段日志信息以后,出错的提示信息一般会出现在最后面,通常是写着 Fatal、Error、Warning 或者 Java Exception 的地方。可以在网上搜索一下出错信息,寻找一些相关的解决方法。

如果执行 jps 命令后,找不到 DataNode 进程,则表示数据节点启动失败,可尝试如下的方法(注意: 这会删除 HDFS 中原有的所有数据,如果原有的数据很重要,请不要这样做,不过对于初学者而言,通常这个时候不会有重要数据):

\$./sbin/stop-dfs.sh #关闭
\$rm-r./tmp #删除 tmp 文件,注意: 这会删除 HDFS 中原有的所有数据
\$./bin/hdfs namenode - format #重新格式化名称节点
\$./sbin/start-dfs.sh #重启

#### 5. 使用 Web 界面查看 HDFS 信息

Hadoop 成功启动后,可以在 Linux 系统中(不是 Windows 系统)打开一个浏览器,在地址栏输入地址 http://localhost:50070(见图 3-7)就可以查看名称节点和数据节点信息,还可以在线查看 HDFS 中的文件。

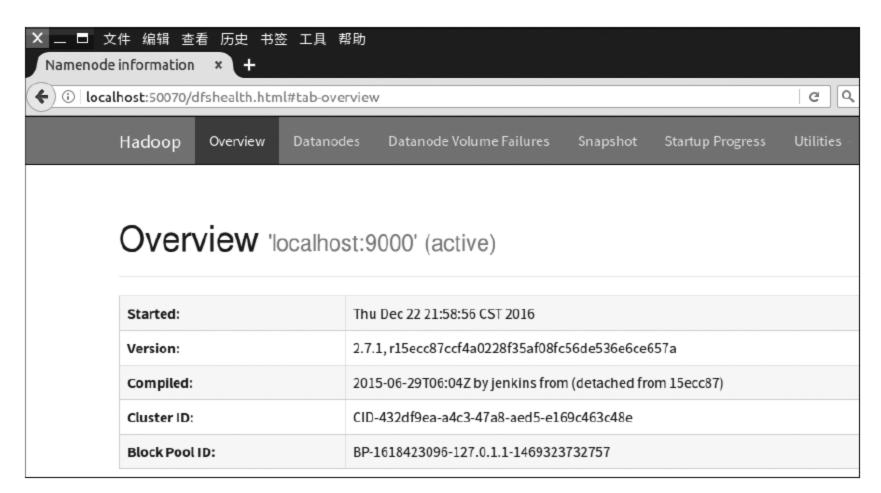


图 3-7 HDFS 的 Web 管理界面

# 6. 运行 Hadoop 伪分布式实例

在上面的单机模式中,grep 例子读取的是本地数据,在伪分布式模式下,读取的则是分布式文件系统 HDFS 上的数据。要使用 HDFS,首先需要在 HDFS 中创建用户目录(本书全部统一采用 hadoop 用户名登录 Linux 系统),命令如下:

\$cd /usr/local/hadoop \$./bin/hdfs dfs -mkdir -p /user/hadoop 上面的命令是分布式文件系统 HDFS 的操作命令,会在后面的第4章中做详细介绍,目前只需要按照命令操作即可。

接着需要把本地文件系统的/usr/local/hadoop/etc/hadoop 目录中的所有 xml 文件作为输入文件,复制到分布式文件系统 HDFS 中的/user/hadoop/input 目录中,命令如下:

\$cd /usr/local/hadoop

- \$./bin/hdfs dfs mkdir input #在 HDFS 中创建 hadoop 用户对应的 input 目录
- \$./bin/hdfs dfs put ./etc/hadoop/\* .xml input #把本地文件复制到 HDFS 中

复制完成后,可以通过如下命令查看 HDFS 中的文件列表:

\$./bin/hdfs dfs - ls input

执行上述命令以后,可以看到 input 目录下的文件信息。 现在就可以运行 Hadoop 自带的 grep 程序,命令如下:

```
$./bin/hadoop jar ./share/hadoop/mapreduce/hadoop-mapreduce-examples- * .
jar grep input output 'dfs[a-z.]+'
```

运行结束后,可以通过如下命令查看 HDFS 中的 output 文件夹中的内容:

```
$./bin/hdfs dfs - cat output/ *
```

执行结果如图 3-8 所示。

```
hadoop@DBLab-XMU:/usr/local/hadoop$ bin/hdfs dfs -cat output/*

1 dfsadmin

1 dfs.replication

1 dfs.namenode.name.dir

1 dfs.datanode.data.dir
```

图 3-8 在 Hadoop 伪分布式模式下运行 grep 的结果

需要强调的是, Hadoop 运行程序时,输出目录不能存在,否则会提示如下错误信息:

```
org.apache.hadoop.mapred.FileAlreadyExistsException: Output directory hdfs://localhost: 9000/user/hadoop/output already exists
```

因此,若要再次执行 grep 程序,需要执行如下命令删除 HDFS 中的 output 文件夹:

```
$./bin/hdfs dfs - rm - r output #删除 output 文件夹
```

#### 7. 关闭 Hadoop

如果要关闭 Hadoop,可以执行下面命令:

\$cd /usr/local/hadoop
\$./sbin/stop-dfs.sh

下次启动 Hadoop 时,无须进行名称节点的初始化(否则会出错),也就是说,不要再次执行 hdfs namenode -format 命令,每次启动 Hadoop 只需要直接运行 start-dfs. sh 命令即可。

#### 8. 启动 YARN

需要说明的是,本部分关于 YARN 的内容可以仅作为了解,不需要实际操作,本书在后面章节的所有操作环节都不会启动 YARN。如果读者按照下面介绍的 YARN 配置方法进行了实际操作,那么,在操作结束后,请删除相关的 YARN 配置文件,恢复原来配置,确保后面其他步骤不会出现问题。

假设刚才已经关闭了 Hadoop,现在按照上面介绍的方法,使用如下命令再次启动 Hadoop:

\$cd /usr/local/hadoop \$./sbin/start-dfs.sh

启动成功后,使用jps命令,查看进程,会发现,只有以下几个进程:

SecondaryNameNode

Jps

DataNode

NameNode

可以看出,在上面运行 Hadoop 过程中并没有启动 YARN。YARN 是 Hadoop 2.0以后新增的专门负责资源管理与任务调度的组件,MapReduce 作业可以运行在 YARN 之上,由 YARN 负责为 MapReduce 作业进行资源管理和任务调度。但是,YARN 对于分布式模式(真正由多台机器构成的集群环境)才有意义,伪分布式模式下,YARN 无法真正发挥作用,因此,伪分布式模式下不需要借助于 YARN 为 MapReduce 作业进行资源管理和任务调度,而是可以直接借助于 Hadoop 自身内置的 mapred. LocalJobRunner 来为 MapReduce 作业进行资源管理和任务调度,也就是说,不启动 YARN,MapReduce 程序也能够正常运行。不过,这里仍然要介绍一下伪分布模式下如何配置和启动 YARN,让 YARN 来负责资源管理与任务调度。

首先修改配置文件/usr/local/hadoop/etc/hadoop/mapred-site.xml,这个文件可以从mapred-site.xml.template重命名后得到,命令如下:

\$cd /usr/local/hadoop

\$mv ./etc/hadoop/mapred-site.xml.template ./etc/hadoop/mapred-site.xml

然后使用 vim 编辑器打开 mapred-site. xml 文件,把配置修改为如下内容:

接着修改配置文件/usr/local/hadoop/etc/hadoop/yarn-site.xml,把配置修改为如下内容:

现在就可以启动 Hadoop 和 YARN 了,命令如下:

```
$./sbin/start-dfs.sh #启动 Hadoop
$./sbin/start-yarn.sh #启动 YARN
$./sbin/mr-jobhistory-daemon.sh start historyserver
#开启历史服务器,才能在 Web 中查看任务运行情况
```

开启后,可以通过 jps 命令查看当前运行的进程,可以看到多了 NodeManager 和 ResourceManager 两个后台进程,如图 3-9 所示。

```
nadoop@DBLab-XMU: /usr/local/hadoop
hadoop@DBLab-XMU:/usr/local/hadoop$ ./sbin/start-yarn.sh
starting yarn daemons
starting resourcemanager, logging to /usr/local/hadoop/logs/yarn-hadoop-resource
hanager-DBLab-XMU.out
Localhost: starting nodemanager, logging to /usr/local/hadoop/logs/yarn-hadoop-n
bdemanager-DBLab-XMU.out
hadoop@DBLab-XMU:/usr/local/hadoop$ jps
                                                        启动YARN的输出信息
13519 NameNode
13829 <u>SecondaryName</u>Node
15284 NodeManager
                    成功启动后多了 NodeManager 和 ResourceManager
15317 Jps
13633 DataNode
15163 ResourceManager
```

图 3-9 启动 YARN 后 jps 命令执行结果

启动 YARN 之后,运行实例的方法和伪分布式模式是一样的,仅仅是资源管理、任务调度方式不同。观察日志信息可以发现,不启用 YARN 时,是 mapred. LocalJobRunner 在跑任务;启用 YARN 之后,是 mapred. YARNRunner 在跑任务。启动 YARN 还有个好处,那就是可以通过 Web 界面查看任务的运行情况,如图 3-10 所示。

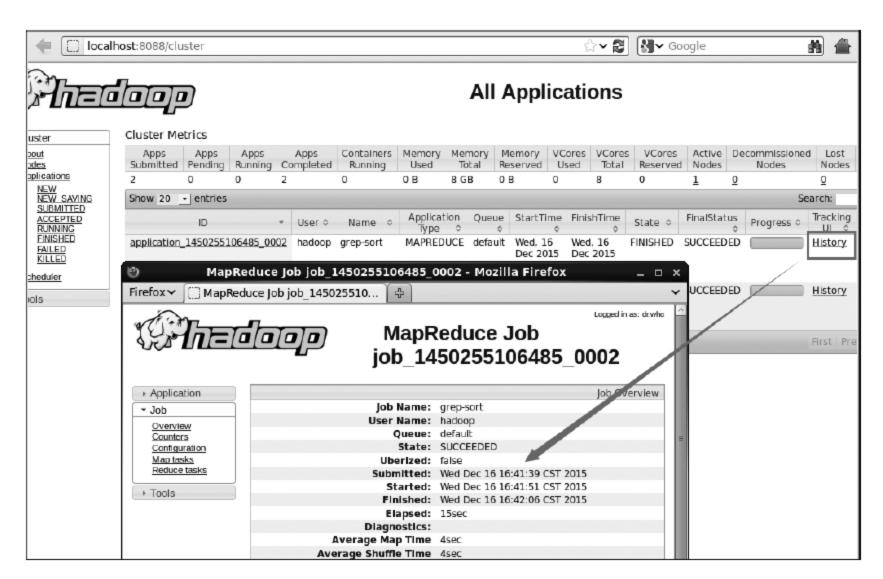


图 3-10 通过 Web 界面查看任务的运行情况

关闭 YARN 和 Hadoop 的脚本如下:

- \$./sbin/stop-yarn.sh
- \$./sbin/mr-jobhistory-daemon.sh stop historyserver
- \$./sbin/stop-dfs.sh

需要注意的是,在经过上述测试以后,如果以后在伪分布式模式下启动 Hadoop 的时候不想同时启动 YARN,则务必把配置文件 mapred-site. xml 重命名,改成 mapred-site. xml. template,需要用时改回来即可。否则,如果该配置文件存在,使用 start-dfs. sh 命令启动 Hadoop 以后却未开启 YARN,则运行程序时会提示"Retrying connect to server: 0.0.0.0.0/0.0.0.8032"错误。

### 9. 配置 PATH 变量

前面在启动 Hadoop 时,都要加上命令的路径,例如,./sbin/start-dfs.sh 这个命令中就带上了路径,实际上,通过设置 PATH 变量,可以在执行命令时,不用带上命令本身所在的路径。例如,打开一个 Linux 终端,在任何一个目录下执行 ls 命令时,都没有带上 ls 命令的路径,实际上,执行 ls 命令时,是执行/bin/ls 这个程序,之所以不需要带上路径,是因为Linux 系统已经把 ls 命令的路径加入到 PATH 变量中,当执行 ls 命令时,系统是根据PATH 这个环境变量中包含的目录位置,逐一进行查找,直至在这些目录位置下找到匹配的 ls 程序(若没有匹配的程序,则系统会提示该命令不存在)。

知道了这个原理以后,同样可以把 start-dfs. sh、stop-dfs. sh 等命令所在的目录/usr/local/hadoop/sbin,加入到环境变量 PATH 中,这样,以后在任何目录下都可以直接使用命令 start-dfs. sh 启动 Hadoop,不用带上命令路径。具体操作方法是,首先使用 vim 编辑器打开~/. bashrc 这个文件,然后在这个文件的最前面位置加入如下单独一行:

export PATH= \$PATH:/usr/local/hadoop/sbin

在后面的学习过程中,如果要继续把其他命令的路径也加入到 PATH 变量中,也需要继续修改~/. bashrc 这个文件。当后面要继续加入新的路径时,只要用英文冒号":"隔开,把新的路径加到后面即可,例如,如果要继续把/usr/local/hadoop/bin 路径增加到 PATH中,只要继续追加到后面,如下所示:

export PATH= \$PATH:/usr/local/hadoop/sbin:/usr/local/hadoop/bin

添加后,执行命令 source  $\sim$ /. bashrc 使设置生效。设置生效后,在任何目录下启动 Hadoop,都只要直接输入 start-dfs. sh 命令即可。同理,停止 Hadoop,也只需要在任何目录下输入 stop-dfs. sh 命令即可。

### 3.3.4 分布式模式配置

当 Hadoop 采用分布式模式部署和运行时,存储采用分布式文件系统 HDFS,而且, HDFS 的名称节点和数据节点位于不同机器上。这时,数据就可以分布到多个节点上,不同 数据节点上的数据计算可以并行执行,这时的 MapReduce 分布式计算能力才能真正发挥 作用。

为了降低分布式模式部署的难度,本书简单使用两个节点(两台物理机器)来搭建集群环境:一台机器作为 Master 节点,局域网 IP 地址为 192.168.1.121;另一台机器作为 Slave 节点,局域网 IP 地址为 192.168.1.122。由 3 个以上节点构成的集群,也可以采用类似的方法完成安装部署。

Hadoop 集群的安装配置大致包括以下步骤。

- (1) 选定一台机器作为 Master。
- (2) 在 Master 节点上创建 hadoop 用户、安装 SSH 服务端、安装 Java 环境。
- (3) 在 Master 节点上安装 Hadoop,并完成配置。
- (4) 在其他 Slave 节点上创建 hadoop 用户、安装 SSH 服务端、安装 Java 环境。
- (5) 将 Master 节点上的/usr/local/hadoop 目录复制到其他 Slave 节点上。
- (6) 在 Master 节点上开启 Hadoop。

上述这些步骤中,关于如何创建 hadoop 用户、安装 SSH 服务端、安装 Java 环境、安装 Hadoop 等过程,已经在前面介绍伪分布式安装的时候做了详细介绍,按照之前介绍的方法完成步骤(1)到步骤(4),这里不再赘述。在完成步骤(1)到步骤(4)的操作以后,才可以继续进行下面的操作。

#### 1. 网络配置

假设集群所用的两个节点(机器)都位于同一个局域网内。如果两个节点使用的是虚拟机安装的 Linux 系统,那么两者都需要更改网络连接方式为"桥接网卡"模式(可以参考第 2 章中介绍的网络连接设置方法),才能实现多个节点互连,如图 3-11 所示。此外,一定要确保各个节点的 MAC 地址不能相同,否则会出现 IP 冲突。在第 2 章曾介绍过采用导入虚拟

机镜像文件的方式安装 Linux 系统,如果是采用这种方式安装 Linux 系统,则有可能出现两台机器的 MAC 地址是相同的,因为一台机器复制了另一台机器的配置。因此,需要改变机器的 MAC 地址,如图 3-11 所示,可以单击界面右边的"刷新"按钮随机生成 MAC 地址,这样就可以让两台机器的 MAC 地址不同了。



图 3-11 网络连接方式设置

网络配置完成以后,可以查看一下机器的 IP 地址,可以使用在第 2 章介绍过的 ifconfig 命令查看。本书在同一个局域网内部的两台机器的 IP 地址分别是 192.168.1.121 和 192.168.1.122。

由于集群中有两台机器需要设置,所以,在接下来的操作中,一定要注意区分 Master 节点和 Slave 节点。为了便于区分 Master 节点和 Slave 节点,可以修改各个节点的主机名,这样,在 Linux 系统中打开一个终端以后,在终端窗口的标题和命令行中都可以看到主机名,就比较容易区分当前是对哪台机器进行操作。在 Ubuntu 中,在 Master 节点上执行如下命令修改主机名:

\$sudo vim /etc/hostname

执行上面命令后,就打开了/etc/hostname 这个文件,这个文件里面记录了主机名,例如,本书在第2章中安装 Ubuntu 系统时,设置的主机名是 dblab-VirtualBox,因此,打开这个文件以后,里面就只有 dblab-VirtualBox 这一行内容,可以直接删除,并修改为 Master (注意是区分大小写的);然后保存并退出 vim 编辑器,这样就完成了主机名的修改,需要重启 Linux 系统才能看到主机名的变化。

要注意观察主机名修改前后的变化。在修改主机名之前,如果用 hadoop 登录 Linux 系统,打开终端,进入 Shell 命令提示符状态,会显示如下内容:

hadoop@dblab-VirtualBox:~\$

修改主机名并且重启系统之后,用 hadoop 登录 Linux 系统,打开终端,进入 Shell 命令提示符状态,会显示如下内容:

hadoop@Master:~\$

可以看出,这时就很容易辨认出当前是处于 Master 节点上进行操作,不会和 Slave 节点产生混淆。

然后执行如下命令打开并修改 Master 节点中的/etc/hosts 文件:

\$sudo vim /etc/hosts

可以在 hosts 文件中增加如下两条 IP 和主机名映射关系:

192.168.1.121 Master 192.168.1.122 Slavel

修改后的效果如图 3-12 所示。



图 3-12 修改 IP 和主机名映射关系后的效果

需要注意的是,一般 hosts 文件中只能有一个 127.0.0.1,其对应主机名为 localhost,如果有多余 127.0.0.1 映射,应删除,特别是不能存在 127.0.0.1 Master 这样的映射记录。修改后需要重启 Linux 系统。

上面完成了 Master 节点的配置,接下来要继续完成对其他 Slave 节点的配置修改。本书只有一个 Slave 节点,主机名为 Slave1。参照上面的方法,把 Slave 节点上的/etc/hostname 文件中的主机名修改为 Slave1,同时,修改/etc/hosts 的内容,在 hosts 文件中增加如下两条 IP 和主机名映射关系:

```
192.168.1.121 Master
192.168.1.122 Slavel
```

修改完成以后,重新启动 Slave 节点的 Linux 系统。

这样就完成了 Master 节点和 Slave 节点的配置,然后,需要在各个节点上都执行如下命令,测试是否相互 ping 得通,如果 ping 不通,后面就无法顺利配置成功:

```
$ping Master-c3 #只 ping 3次就会停止,否则要按 Ctrl+C键中断 ping命令
$ping Slave1-c3
```

例如,在 Master 节点上 ping Slave1,如果 ping 通的话,会显示如图 3-13 所示的结果。

#### 2. SSH 无密码登录节点

必须要让 Master 节点可以 SSH 无密码登录到各个 Slave 节点上。首先,生成 Master

```
hadoop@Master:~
hadoop@Master:~
hadoop@Master:~
ping Slave1 -c 3
PING Slave1 (192.168.1.122) 56(84) bytes of data.
64 bytes from Slave1 (192.168.1.122): icmp_seq=1 ttl=64 time=0.315 ms
64 bytes from Slave1 (192.168.1.122): icmp_seq=2 ttl=64 time=0.427 ms
64 bytes from Slave1 (192.168.1.122): icmp_seq=3 ttl=64 time=0.338 ms

--- Slave1 ping statistics ---
3 packets transmitted, 3 received, 0% packet loss, time 1999ms
rtt min/avg/max/mdev = 0.315/0.360/0.427/0.048 ms
```

图 3-13 使用 ping 命令的效果

节点的公匙,如果之前已经生成过公匙,必须要删除原来生成的公匙,重新生成一次,因为前面对主机名进行了修改。具体命令如下:

```
$cd ~/.ssh #如果没有该目录,先执行一次 ssh localhost
$rm ./id_rsa * #删除之前生成的公匙(如果已经存在)
$ssh- keygen - t rsa #执行该命令后,遇到提示信息,一直按 Etner 键就可以
```

为了让 Master 节点能够无密码 SSH 登录本机,需要在 Master 节点上执行如下命令:

```
$cat ./id_rsa.pub >> ./authorized_keys
```

完成后可以执行命令 ssh Master 来验证一下,可能会遇到提示信息,只要输入 yes 即可,测试成功后,执行 exit 命令返回原来的终端。

接下来在 Master 节点将上公匙传输到 Slavel 节点:

```
scp ~/.ssh/id_rsa.pub hadoop@ Slavel:/home/hadoop/
```

上面的命令中,scp是 secure copy的简写,用于在 Linux 下进行远程复制文件,类似于cp命令,不过,cp只能在本机中复制。执行 scp时会要求输入 Slave1上 hadoop用户的密码,输入完成后会提示传输完毕,如图 3-14 所示。

```
Madoop@Master: ~/.ssh$ scp ~/.ssh/id_rsa.pub hadoop@Slave1:/home/hadoop/
The authenticity of host 'slave1 (192.168.1.122)' can't be established.

ECDSA key fingerprint is e3:40:14:58:1c:37:4d:21:a0:24:bf:00:e6:a0:fb:2f.

Are you sure you want to continue connecting (yes/no)? yes

Warning: Permanently added 'slave1,192.168.1.122' (ECDSA) to the list of known hosts.

hadoop@slave1's password:

id_rsa.pub

100% 395 0.4KB/s 00:00

hadoop@Master:~/.ssh$
```

图 3-14 执行 scp 命令的效果

接着在 Slavel 节点上将 SSH 公匙加入授权:

```
$mkdir ~/.ssh #如果不存在该文件夹需先创建,若已存在,则忽略本命令
$cat ~/id_rsa.pub>> ~/.ssh/authorized_keys
$rm ~/id_rsa.pub #用完以后就可以删掉
```

如果有其他 Slave 节点,也要执行将 Master 公匙传输到 Slave 节点以及在 Slave 节点 上加入授权这两步操作。

这样,在 Master 节点上就可以无密码 SSH 登录到各个 Slave 节点了,可在 Master 节点上执行如下命令进行检验:

\$ssh Slave1

执行该命令的效果如图 3-15 所示。

```
■ hadoop@Slave1: ~

hadoop@Master:~/.ssh$ ssh Slave1 注意 是在 Master 上执行的 ssh
Welcome to Ubuntu 14.04.1 LTS (GNU/Linux 3.13.0-32-generic x86_64)

* Documentation: https://help.ubuntu.com/

549 packages can be updated.
245 updates are security updates.

Last login: Sat Dec 19 19:09:57 2015 from master hadoop@Slave1 ~$ ssh登录后,终端标题以及命令符变为 Slave1 hadoop@Slave1:~$ 此时执行的命令等同于在 Slave1 节点上执行 hadoop@Slave1:~$ (可执行 exit 退回到原来的 Master 终端)
```

图 3-15 ssh 命令执行效果

#### 3. 配置 PATH 变量

在前面的伪分布式安装内容中,已经介绍过 PATH 变量的配置方法。可以按照同样的方法进行配置,这样就可以在任意目录中直接使用 hadoop、hdfs 等命令了。如果还没有配置 PATH 变量,那么需要在 Master 节点上进行配置。首先执行命令 vim ~/. bashrc,也就是使用 vim 编辑器打开~/. bashrc 文件;然后,在该文件最上面的位置加入下面一行内容:

export PATH= \$PATH:/usr/local/hadoop/bin:/usr/local/hadoop/sbin

保存后执行命令 source ~/. bashrc,使配置生效。

#### 4. 配置集群/分布式环境

在配置集群/分布式模式时,需要修改/usr/local/hadoop/etc/hadoop 目录下的配置文件,这里仅设置正常启动所必需的设置项,包括 slaves、core-site. xml、hdfs-site. xml、mapred-site. xml、yarn-site. xml 共 5 个文件,更多设置项可查看官方说明。

#### 1) 修改文件 slaves

需要把所有数据节点的主机名写入该文件,每行一个,默认为 localhost(即把本机作为数据节点),所以,在伪分布式配置时,就采用了这种默认的配置,使得节点既作为名称节点也作为数据节点。在进行分布式配置时,可以保留 localhost,让 Master 节点同时充当名称节点和数据节点,或者也可以删掉 localhost 这行,让 Master 节点仅作为名称节点使用。

本书让 Master 节点仅作为名称节点使用,因此将 slaves 文件中原来的 localhost 删除,只添加如下一行内容:

Slave1

#### 2) 修改文件 core-site. xml

把 core-site. xml 文件修改为如下内容:

各个配置项的含义可以参考前面伪分布式模式时的介绍,这里不再赘述。

#### 3) 修改文件 hdfs-site. xml

对于 Hadoop 的分布式文件系统 HDFS 而言,一般都是采用冗余存储,冗余因子通常为3,也就是说,一份数据保存3份副本。但是,本书只有一个 Slave 节点作为数据节点,即集群中只有一个数据节点,数据只能保存一份,所以,dfs. replication 的值还是设置为1。hdfs-site. xml 的具体内容如下:

```
<configuration>
       cproperty>
               <name>dfs.namenode.secondary.http-address/name>
               <value>Master:50090
       </property>
       cproperty>
               <name>dfs.replication</name>
               < value> 1< /value>
       </property>
       cproperty>
             <name>dfs.namenode.name.dir
               <value>file:/usr/local/hadoop/tmp/dfs/name
       </property>
       cproperty>
               <name>dfs.datanode.data.dir
               <value>file:/usr/local/hadoop/tmp/dfs/data</value>
       </property>
</configuration>
```

#### 4) 修改文件 mapred-site. xml

/usr/local/hadoop/etc/hadoop 目录下有一个 mapred-site. xml. template,需要修改文件名称,把它重命名为 mapred-site. xml,然后把 mapred-site. xml 文件配置成如下内容:

# 5) 修改文件 yarn-site. xml

把 yarn-site. xml 文件配置成如下内容:

上述 5 个文件全部配置完成以后,需要把 Master 节点上的/usr/local/hadoop 文件夹复制到各个节点上。如果之前已经运行过伪分布式模式,建议在切换到集群模式之前首先删除之前在伪分布式模式下生成的临时文件。具体来说,需要首先在 Master 节点上执行如下命令:

```
$cd /usr/local
$sudo rm - r ./hadoop/tmp #删除 Hadoop 临时文件
$sudo rm - r ./hadoop/logs/* #删除日志文件
$tar - zcf ~/hadoop.master.tar.gz ./hadoop #先压缩再复制
$cd ~
$scp ./hadoop.master.tar.gz Slavel:/home/hadoop
```

然后在 Slavel 节点上执行如下命令:

```
$sudo rm - r /usr/local/hadoop #删掉旧的(如果存在)
$sudo tar - zxf ~/hadoop.master.tar.gz-C /usr/local
$sudo chown - R hadoop /usr/local/hadoop
```

同样,如果有其他 Slave 节点,也要执行将 hadoop. master. tar. gz 传输到 Slave 节点以及在 Slave 节点解压文件的操作。

首次启动 Hadoop 集群时,需要先在 Master 节点执行名称节点的格式化(只需要执行这一次,后面再启动 Hadoop 时,不要再次格式化名称节点),命令如下:

```
$hdfs namenode - format
```

现在就可以启动 Hadoop 了,启动需要在 Master 节点上进行,执行如下命令:

```
$start-dfs.sh
$start-yarn.sh
$mr-jobhistory-daemon.sh start historyserver
```

通过命令 jps 可以查看各个节点所启动的进程。如果已经正确启动,则在 Master 节点上可以看到 NameNode、ResourceManager、SecondrryNameNode 和 JobHistoryServer 进程,如图 3-16 所示。

在 Slave 节点可以看到 DataNode 和 NodeManager 进程,如图 3-17 所示。

图 3-16 Master 节点上启动的进程

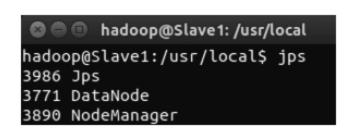


图 3-17 Slave 节点上启动的进程

缺少任一进程都表示出错。另外还需要在 Master 节点上通过命令 hdfs dfsadmin - report 查看数据节点是否正常启动,如果屏幕信息中的 Live datanodes 不为 0,则说明集群启动成功。由于本书只有一个 Slave 节点充当数据节点,因此,数据节点启动成功以后,会显示如图 3-18 所示的信息。

也可以在 Linux 系统的浏览器中输入地址 http://master:50070/,通过 Web 页面看到 查看名称节点和数据节点的状态。如果不成功,可以通过启动日志排查原因。

这里再次强调,伪分布式模式和分布式模式切换时需要注意以下事项。

- (1) 从分布式切换到伪分布式时,不要忘记修改 slaves 配置文件。
- (2) 在两者之间切换时,若遇到无法正常启动的情况,可以删除所涉及节点的临时文件夹,这样虽然之前的数据会被删掉,但能保证集群正确启动。所以,如果集群以前能启动,但后来启动不了,特别是数据节点无法启动,不妨试着删除所有节点(包括 Slave 节点)上的/usr/local/hadoop/tmp文件夹,再重新执行一次 hdfs namenode -format,再次启动即可。

```
Decommission Status: Normal
Configured Capacity: 7262953472 (6.76 GB)
DFS Used: 24576 (24 KB)
Non DFS Used: 5365833728 (5.00 GB)
DFS Remaining: 1897095168 (1.77 GB)
DFS Used%: 0.00%
DFS Remaining%: 26.12%
Configured Cache Capacity: 0 (0 B)
```

图 3-18 通过 dfsadmin 查看数据节点的状态

### 5. 执行分布式实例

执行分布式实例过程与伪分布式模式一样,首先创建 HDFS 上的用户目录,命令如下:

```
$hdfs dfs -mkdir -p /user/hadoop
```

然后在 HDFS 中创建一个 input 目录,并把/usr/local/hadoop/etc/hadoop 目录中的配置文件作为输入文件复制到 input 目录中,命令如下:

```
$hdfs dfs - mkdir input
$hdfs dfs - put /usr/local/hadoop/etc/hadoop/*.xml input
```

接着就可以运行 MapReduce 作业了,命令如下:

```
$hadoop jar /usr/local/hadoop/share/hadoop/mapreduce/hadoop-mapreduce-
examples-*.jar grep input output 'dfs[a-z.]+'
```

运行时的输出信息与伪分布式类似,会显示 MapReduce 作业的进度,如图 3-19 所示。

图 3-19 运行 MapReduce 作业时的输出信息

执行过程可能会有点慢,但是,如果迟迟没有进度,例如 5 分钟都没看到进度变化,那么不妨重启 Hadoop 再次测试。若重启还不行,则很有可能是内存不足引起,建议增大虚拟机的内存,或者通过更改 YARN 的内存配置来解决。

在执行过程中,可以在 Linux 系统中打开浏览器,在地址栏输入 http://master:8088/

cluster,通过 Web 界面查看任务进度,在 Web 界面中单击 Tracking UI 这一列的 History 连接,可以看到任务的运行信息,如图 3-20 所示。

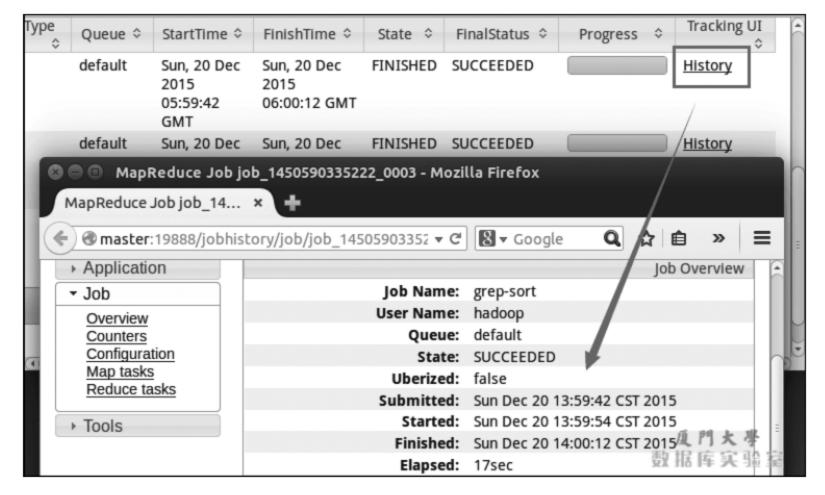


图 3-20 通过 Web 页面查看集群和 MapReduce 作业的信息

执行完毕后的输出结果如图 3-21 所示。

图 3-21 MapReduce 作业执行完毕后的信息

最后关闭 Hadoop 集群,需要在 Master 节点执行如下命令:

```
$stop-yarn.sh
$stop-dfs.sh
$mr-jobhistory-daemon.sh stop historyserver
```

至此,就顺利完成了 Hadoop 集群搭建。

# 3.3.5 使用 Docker 搭建 Hadoop 分布式集群

搭建 Hadoop 分布式集群通常容易想到的两种方法如下:

- (1) 采用多台机器构建分布式集群;
- (2) 在一台机器上,安装多个虚拟机,每个虚拟机上运行一个 Hadoop 节点。

但是,上述两种方式都有缺点。如果采用第一种方法,通常需要有多台机器,对于很多

大数据学习者而言,通常难以找到多台机器用于构建分布式实验环境;如果采用第二种方法,通常对单台机器的配置要求很高,如果机器配置较低,那么在一台机器上同时运行多个虚拟机,速度会非常慢。

随着虚拟化技术的发展,尤其是 Docker 容器技术的诞生,使得人们可以有了第 3 种构建 Hadoop 分布式集群的方法——使用 Docker 搭建 Hadoop 分布式集群。

#### 1. Docker 简介

Docker 是一个开源的应用容器引擎,让开发者可以把应用及其依赖包一起打包到一个可移植的容器中,然后发布到任何 Linux 机器上。Docker 也可以实现虚拟化,而且,Docker 是不同于 VMware 等传统虚拟化技术的一种新型轻量级虚拟化技术(也被称为"容器型虚拟化技术")。与 VMware 等传统虚拟化技术相比,Docker 容器具有启动速度快、资源利用率高、性能开销小等优点,受到业界青睐,并得到了越来越广泛的应用。不过,需要注意的是,Docker 是基于 64 位 Linux 的,无法在 32 位的 Linux/Windows/UNIX 环境下使用。

#### 2. 安装 Docker

安装 Docker 之前,必须首先保证机器上安装的是 64 位 Linux 系统;其次,内核版本必须大于 3.10。可以用如下命令来检测机器上已经安装好的 Ubuntu 系统的内核版本:

\$uname - r

然后需要先更新 apt,安装 CA 证书,因为访问 Docker 使用的是 HTTPS 协议,命令如下:

\$sudo apt-get update
\$sudo apt-get install apt-transport-https ca-certificates

执行如下命令添加新的 GPG key:

\$sudo apt-key adv \

- -- keyserver hkp://ha.pool.sks-keyservers.net:80 \
- -- recv-keys 58118E89F3A912897C070ADBF76221572C52609D

执行如下命令为 Ubuntu 系统添加 Docker 安装源(也就是可以获得 Docker 安装包的地方):

\$echo deb https://apt.dockerproject.org/repo ubuntu-xenial main | sudo tee
/etc/apt/sources.list.d/docker.list

执行如下命令更新 apt 软件列表:

\$sudo apt-get update

接着可以用如下命令验证一下是否从正确的仓库拉取安装包:

\$apt-cache policy docker-engine

如果有类似于下面的输出,则说明从正确的仓库获取包:

docker-engine:

Installed: 1.12.2-0~trusty Candidate: 1.12.2-0~trusty

Version table:

\*\*\* 1.12.2-0~trusty 0

500 https://apt.dockerproject.org/repo/ubuntu-trusty/main amd64 Packages

100 /var/lib/dpkg/status

1.12.1-0~trusty 0

500 https://apt.dockerproject.org/repo/ubuntu-trusty/main amd64 Packages

1.12.0-0~trusty 0

500 https://apt.dockerproject.org/repo/ubuntu-trusty/main amd64 Packages

接下来可以直接安装 Docker,命令如下:

\$sudo apt-get install docker-engine

等这个命令结束之后, Docker 即安装完成。可以通过下面命令开启 Docker 服务:

\$sudo service docker start

然后可以运行 Docker 官方提供的 hello-world 程序来检测 Docker 是否能够顺利运行程序:

\$sudo docker run hello-world

执行上述命令以后,屏幕上会返回很多信息,如果其中包含如下所示信息,则表示安装成功:

Hello from Docker!

This message shows that your installation appears to be working correctly.

对于 Docker 而言,默认情况下只有 root 用户才能执行 Docker 命令,因此,还需要添加用户权限。首先需要使用如下命令创建 Docker 用户组:

\$sudo groupadd docker

然后添加当前用户到 Docker 用户组,命令如下:

\$sudo usermod - aG docker hadoop

由于本书全部采用 hadoop 用户登录 Linux 系统,所以,上面的命令中使用了 hadoop 用户名。执行上述命令以后,需要注销当前登录,然后再次用 hadoop 用户登录系统,就可以顺畅地执行 Docker 命令了。

#### 3. 在 Docker 上安装 Ubuntu 系统

安装好 Docker 之后,接下来就要在 Docker 上安装 Ubuntu。可以直接从 Docker 上下载 Ubuntu 镜像文件,命令如下:

\$docker pull ubuntu

docker pull 命令表示从 Docker hub 上拉取 Ubuntu 镜像到本地。执行该命令以后,可以在执行下面命令查看是否安装成功:

\$docker images

docker images 表示列出 Docker 上所有的镜像。镜像也是一堆文件,如果输出类似如下的信息则表示安装成功:

REPOSITORY TAG IMAGE ID CREATED SIZE ubuntu latest 4ca3a192ff2a 11days ago 128.2 MB

然后需要在 Docker 上开启 Ubuntu 系统,也就是启动 Ubuntu 镜像。在启动 Ubuntu 镜像之前,需要先在当前登录用户(hadoop)的用户目录下创建一个子目录,用于向 Docker 内部的 Ubuntu 系统传输文件,请在本地 Ubuntu 系统(不是 Docker 中的 Ubuntu 系统)中执行如下命令:

\$cd ~

\$mkdir build

现在就可以在 Docker 上启动运行 Ubuntu 系统了,在本地 Ubuntu 系统中执行如下命令:

\$docker run - it - v /home/hadoop/build:/root/build - - name ubuntu ubuntu

上面命令的含义如下。

- (1) docker run 表示运行一个镜像。
- (2) -i 表示开启交互式;-t 表示分配一个 tty(可以理解为一个控制台);因此,-it 可以理解为在当前终端上与 Docker 内部的 Ubuntu 系统进行交互。
  - (3) -v 表示 Docker 内部的 Ubuntu 系统中的/root/build 目录与本地的/home/

hadoop/build 目录共享,这样就可以很方便地将本地文件上传到 Docker 内部的 Ubuntu 系统中。

- (4) --name ubuntu 表示 Ubuntu 镜像启动名称,如果没有指定,那么 Docker 将会随机分配一个名字。
  - (5) ubuntu: 命令中的最后一个 ubuntu,表示 docker run 启动的镜像文件。

#### 4. Ubuntu 系统初始化

刚安装好的 Ubuntu 系统,是一个很纯净的系统,很多软件是没有安装的,所以需要先更新一下 Ubuntu 系统的软件源并安装一些必备的软件。

1) 更新系统软件源

在 Docker 上的 Ubuntu 系统(不是本地 Ubuntu 系统)中执行下面命令更新软件源:

\$apt-get update

2) 安装 vim 编辑器

在 Docker 上的 Ubuntu 系统中执行下面命令安装 vim 编辑器:

\$apt-get install vim

3) 安装和配置 sshd

接着安装 sshd,因为在开启分布式 Hadoop 时,需要用到 SSH 连接 Slave 机器,在 Docker 上的 Ubuntu 系统中执行如下命令:

\$apt-get install ssh

然后在 Docker 上的 Ubuntu 系统中运行如下脚本即可开启 sshd 服务器:

\$/etc/init.d/ssh start

但是,这样每次在启动镜像时,都需要手动开启 sshd 服务,因此,可以把启动命令写进 ~/. bashrc 文件,从而在每次登录 Ubuntu 系统时,都能自动启动 sshd 服务。用 vim 编辑器打开~/. bashrc 文件,在该文件最后一行添加如下内容:

/etc/init.d/ssh start

安装好 sshd 之后,需要配置 SSH 无密码连接本地 sshd 服务,在 Docker 上的 Ubuntu 系统中执行如下命令:

\$ssh-keygen -t rsa #一直按 Enter 键即可

\$cd ~./ssh

\$cat id\_dsa.pub >> authorized\_keys

执行完上述命令之后,即可无密码访问本地 sshd 服务。

#### 4) 安装 Java

因为 Hadoop 需要使用 Java 环境,因此,需要安装 JDK。可以在 Docker 上的 Ubuntu 系统中直接输入以下命令来安装 JDK:

\$apt-get install default-jdk

这个命令会安装比较多的库,并会消耗较长时间。等待这个命令运行结束之后,JDK 安装就顺利完成了。然后,需要配置环境变量,打开~/. bashrc 文件,在文件的最开始位置 增加如下内容:

export JAVA\_HOME=/usr/lib/jvm/java-8-openjdk-amd64/export PATH=\$PATH:\$JAVA\_HOME/bin

接着在 Docker 上的 Ubuntu 系统中执行如下命令使~/. bashrc 配置文件生效:

\$source ~/.bashrc

#### 5) 保存镜像文件

在 Docker 内部对容器做的修改,是不会自动保存到镜像中的,也就是说,上面尽管对容器进行了大量配置,但是,一旦把容器关闭,然后重新开启容器,则之前的设置会全部消失;因此,需要保存当前的容器配置。为了达到复用容器的配置信息,在每个步骤完成之后,都应该保存成一个新的镜像,然后开启并运行保存后的新镜像即可。为了把容器配置保存成新的镜像,首先需要到 Docker 官网(https://hub. docker. com/)注册一个账号,账号注册成功后,然后在本地 Ubuntu 系统(不是 Docker 中的 Ubuntu 系统)中新建一个终端,输入如下命令:

\$docker login

然后会有如下提示信息,输入上面注册的用户名和密码即可:

Login with your Docker ID to push and pull images from Docker Hub. If you don't have a Docker ID, head over to https://hub.docker.com to create one.

Username:

Password:

Login Succeeded

登录之后,首先在本地 Ubuntu 系统中使用如下命令查看当前运行的容器的信息:

\$docker ps

#### 输出结果如下:

```
CONTAINER ID IMAGE COMMAND CREATED STATUS PORTS NAMES fdlfc69d75a3 ubuntu "/bin/bash" About an hour ago Up About an hour ubuntu
```

从上面的结果信息可以看出,当前运行的 Ubuntu 镜像的 ID 是 fd1fc69d75a3。然后在本地 Ubuntu 系统中输入以下命令,把修改后的容器保存成为一个新的镜像,新镜像的名称是 ubuntu/jdkinstalled,表示该镜像中已经包含了 JDK:

```
$docker commit fd1fc69d75a3 ubuntu/jdkinstalled
```

其中, docker commit 后面的 fd1fc69d75a3 是当前运行的 Ubuntu 镜像的 ID。输出结果如下:

```
sha256:05c9bc2b849359d029d417421d6968bdd239aad447ac6054c429b630378118aa
```

最后在本地 Ubuntu 系统的另一个终端中使用如下命令查看所有镜像,确认一下新的镜像是否保存成功:

```
$docker images
```

#### 输出结果如下:

```
REPOSITORY TAG IMAGE ID CREATED SIZE
ubuntu/jdkinstalled latest 05c9bc2b8493 9 seconds ago 899.3 MB
ubuntu latest 4ca3a192ff2a 12 days ago 128.2 MB
```

从上面输出结果可以看出,目前系统中已经有两个镜像:一个是 ubuntu 镜像;另一个是刚才新建的镜像 ubuntu/jdkinstalled。

#### 5. 安装 Hadoop

下面开始安装 Hadoop。需要首先在本地 Ubuntu 系统中启动之前保存的镜像 ubuntu/jdkinstalled,命令如下:

```
$ docker run - it - v /home/hadoop/build:/root/build - - name ubuntu - jdkinstalled
ubuntu/jdkinstalled
```

可以在本地 Ubuntu 系统中的另一个终端中使用如下命令查看启动的容器:

```
$docker ps
```

#### 输出结果如下:

\$CONTAINER ID

325a1c2f2f93

**IMAGE** 

ubuntu/jdkinstalled

COMMAND

"/bin/bash"

CREATED

6 seconds ago

STATUS

Up 5 seconds

PORTS NAMES

ubuntu-jdkinstalled

启动容器以后,在这个容器中就运行了 Ubuntu 系统(包含 JDK)。前面已经下载了 Hadoop 安装文件 hadoop-2.7.1. tar. gz,现在需要把该安装文件放到本地 Ubuntu 系统的 共享目录/home/hadoop/build 下面;然后在 Docker 内部 Ubuntu 系统的/root/build 目录即可获取到该 Hadoop 安装文件。实际上,在 Docker 内部的 Ubuntu 系统上面安装 Hadoop 的过程,和之前介绍的单机模式安装 Hadoop 是一样的。具体而言,需要首先在 Docker 内部的 Ubuntu 系统上面输入如下命令对安装文件进行解压缩操作:

\$cd /root/build

\$tar - zxvf hadoop-2.7.1.tar.gz - C /usr/local

如果是单机模式安装 Hadoop,到这里就已经顺利完成了安装,可以运行如下命令测试是否安装正确(在 Docker 内部的 Ubuntu 系统上面运行命令,不是在本地 Ubuntu 系统上面运行命令):

\$cd /usr/local

\$mv ./hadoop-2.7.1 ./hadoop

\$cd hadoop

\$./bin/hadoop version

## 输出的信息如下:

Hadoop 2.7.1

Subversion https://git-wip-us.apache.org/repos/asf/hadoop.git-r

15ecc87ccf4a0228f35af08fc56de536e6ce657a

Compiled by jenkins on 2015-06-29T06:04Z

Compiled with protoc 2.5.0

From source with checksum fc0a1a23fc1868e4d5ee7fa2b28a58a

This command was run using /usr/local/hadoop/share/hadoop/common/hadoop-

common-2.7.1.jar

#### 6. 配置 Hadoop 集群

现在介绍如何配置 Hadoop 集群,需要修改/usr/local/hadoop/etc/hadoop 目录下的配

置文件 hadoop\_env. sh、core-site. xml、hdfs-site. xml、mapred-site. xml 和 yarn-site. xml。 首先使用 vim 编辑器打开 hadoop\_env. sh 文件,命令如下(在 Docker 内部的 Ubuntu 系统中运行命令):

```
$cd /usr/local/hadoop
$vim etc/hadoop/hadoop-env.sh
```

打开 hadoop\_env. sh 文件以后,在该文件的最前面增加如下内容:

```
export JAVA_HOME=/usr/lib/jvm/java-8-openjdk-amd64/
```

然后保存该文件,退出 vim 编辑器。类似地,使用 vim 编辑器打开 core-site. xml 文件, 并在文件中输入以下内容:

使用 vim 编辑器打开 hdfs-site. xml 文件,并在文件中输入以下内容:

再使用 vim 编辑器打开 mapred-site. xml 文件(可以复制 mapred-site. xml. template, 再修改文件名得到 mapred-site. xml 文件),并在文件中输入以下内容:

```
<configuration>
property>
```

最后修改 yarn-site. xml 文件,在该文件中输入以下内容:

至此, Hadoop 集群配置顺利结束。需要首先保存这个镜像,需要在本地 Ubuntu 系统 (不是 Docker 内部的 Ubuntu 系统)的终端中输入如下命令:

```
$docker commit a40b99f869ae ubuntu/hadoopinstalled
```

接下来在本地 Ubuntu 系统中(不是 Docker 内部的 Ubuntu 系统)打开 3 个终端窗口,每个终端上分别启动一个容器运行 ubuntu/hadoopinstalled 镜像,分别表示 Hadoop 集群中的 Master、Slave01 和 Slave02:

```
#在第一个终端中执行下面命令

$docker run - it - h master - - name master ubuntu/hadoopinstalled

#在第二个终端中执行下面命令

$docker run - it - h slave01 - - name slave01 ubuntu/hadoopinstalled

#在第三个终端中执行下面命令

$docker run - it - h slave02 - - name slave02 ubuntu/hadoopinstalled
```

接着需要配置 Master、Slave01 和 Slave02 的地址信息,使得它们可以找到彼此。在 3 个终端中分别打开/etc/hosts 文件,可以查看本机的 IP 和主机名信息,最后得到 3 个 IP 和主机地址信息如下:

```
172.18.0.2 Master
172.18.0.3 Slave01
172.18.0.4 Slave02
```

最后把上述 3 个地址信息分别复制到 Master、Slave01 和 Slave02 的/etc/hosts 文件中,也就是复制到各自 Docker 容器内部的 Ubuntu 系统的/etc/hosts 文件中。然后,可以在作为 Master 节点的 Docker 容器内部的 Ubuntu 系统的终端中,使用如下命令来检测一下 Master 是否可以成功连上 Slave01 和 Slave02:

```
$ssh slave01
$ssh slave02
```

最后还需要打开 Master 节点上的 slaves 文件,输入两个 Slave 节点的主机名,请在 Master 节点中的终端中执行如下命令:

```
$cd/usr/local/hadoop
$vim etc/hadoop/slaves
```

上面命令执行后,就使用 vim 编辑器打开了 slaves 文件,需要修改该文件的配置,把文件中的 localhost 替换成两个 Slave 节点的主机名,分别放在两行上,最终,slaves 文件的内容只有如下两行:

```
Slave01
Slave02
```

至此, Hadoop 集群已经配置完成,现在可以启动集群,在 Master 节点的终端中执行如下命令:

```
$cd /usr/local/hadoop
$bin/hdfs namenode - format
$sbin/start-all.sh
```

这时 Hadoop 集群就已经启动,可以在 Master、Slave01 和 Slave02 这 3 个节点上分别 运行命令 jps 查看运行结果,如图 3-22~图 3-24 所示。

```
root@master:/usr/local/hadoop# jps
789 Jps
199 NameNode
381 SecondaryNameNode
526 ResourceManager
```

图 3-22 在 Master 节点上运行 jps 命令的结果 图 3-23 在 Slave01 节点上运行 jps 命令的结果

```
root@slave02:/usr/local/hadoop# jps
71 DataNode
170 NodeManager
270 Jps
```

图 3-24 在 Slave02 节点上运行 jps 命令的结果

# 7. 运行 Hadoop 程序实例

到目前为止,我们已经采用容器的方式成功启动 Hadoop 分布式集群,接下来,可以运行 Hadoop 自带的 grep 实例进行测试。因为要用到 HDFS,所以,需要先在 HDFS 上创建一个目录,在 Master 节点的终端中执行如下命令:

```
$cd /usr/local/hadoop
$./bin/hdfs dfs -mkdir -p /user/hadoop/input
```

然后将/usr/local/hadoop/etc/hadoop/目录下的所有文件复制到 HDFS 中,需要在 Master 节点的终端中继续执行如下命令:

```
$./bin/hdfs dfs - put ./etc/hadoop/* .xml /user/hadoop/input
```

然后通过 ls 命令查看下是否正确将文件上传到 HDFS,需要在 Master 节点的终端中继续执行如下命令:

```
$./bin/hdfs dfs - ls /user/hadoop/input
```

#### 输出结果如下:

Found 9 items		
- rw- rr	3 root supergroup	4436 2016-12-26 07:40 /user/hadoop/input/
		capacity-scheduler.xml
- rw- rr	3 root supergroup	1090 2016-12-26 07:40 /user/hadoop/input/
		core-site.xml
- rw- r r	3 root supergroup	9683 2016-12-26 07:40 /user/hadoop/input/
		hadoop-policy.xml
- rw- r r	3 root supergroup	1133 2016-12-26 07:40 /user/hadoop/input/
		hdfs-site.xml
- rw- r r	3 root supergroup	620 2016-12-26 07:40 /user/hadoop/input/
		httpfs-site.xml
- rw- r r	3 root supergroup	3518 2016-12-26 07:40 /user/hadoop/input/
		kms-acls.xml
- rw- r r	3 root supergroup	5511 2016-12-26 07:40 /user/hadoop/input/
		kms-site.xml
- rw- r r	3 root supergroup	866 2016-12-26 07:40 /user/hadoop/input/
		mapred-site.xml
- rw- rr	3 root supergroup	947 2016-12-26 07:40 /user/hadoop/input/
		yarn-site.xml

接下来在 Master 节点的终端中继续运行下面命令执行实例程序:

\$./bin/hadoop jar ./share/hadoop/mapreduce/hadoop-mapreduce-examples- \* .jar grep
/user/hadoop/input output 'dfs[a-z.]+'

等待这个程序运行结束之后,就可以在 HDFS 上的 output 目录下查看到运行结果,在 Master 节点的终端中执行如下命令:

\$./bin/hdfs dfs - cat output/\*

运行结果如下:

- 1 dfsadmin
- 1 dfs.replication
- 1 dfs.namenode.name.dir
- 1 dfs.datanode.data.dir

如果得到类似上述的结果,则说明在 Hadoop 分布式集群中顺利执行了 grep 程序。

# 3.4 本章小结

Hadoop 是当前流行的分布式计算框架,在企业中得到了广泛的部署和应用。本章重点介绍如何安装 Hadoop,从而为后续章节开展 HDFS 和 MapReduce 编程实践奠定基础。

Hadoop 是基于 Java 开发的,需要运行在 JVM 中,因此,需要为 Hadoop 配置相应的 Java 环境。Hadoop 包含 3 种安装模式,即单机模式、伪分布式模式和分布式模式。本章分别介绍 3 种不同模式的安装配置方法。在初学阶段,建议采用伪分布式模式配置,这样可以快速构建起 Hadoop 实战环境,有效开展基础编程工作。

Docker 是目前比较热门的容器技术,相对于 VMware 和 VirtualBox 等虚拟化技术而言,Docker 也可以被视为一种轻量级虚拟化技术,可以在普通 PC 上快速构建起 Hadoop 集群,完成相关大数据实验,本章简要介绍了使用 Docker 搭建 Hadoop 分布式集群的方法。

# HDFS 操作方法和基础编程

Hadoop 分布式文件系统(Hadoop Distributed File System, HDFS)是 Hadoop 核心组件之一,它开源实现了谷歌分布式文件系统(Google File System, GFS)的基本思想。HDFS 支持流数据读取和处理超大规模文件,并能够运行在由廉价的普通机器组成的集群上,这主要得益于 HDFS 在设计之初就充分考虑了实际应用环境的特点,即硬件出错在普通服务器集群中是一种常态,而不是异常,因此,HDFS 在设计上采取了多种机制保证在硬件出错的环境中实现数据的完整性。安装 Hadoop 以后,就已经包含了 HDFS 组件,不需要另外安装。

本章首先介绍 HDFS 操作常用的 Shell 命令;然后介绍利用 HDFS 提供的 Web 管理界面查看 HDFS 相关信息;最后,详细讲解如何编写和运行访问 HDFS 的 Java 应用程序。

# 4.1 HDFS 操作常用 Shell 命令

Hadoop 支持很多 Shell 命令,例如 hadoop fs、hadoop dfs 和 hdfs dfs 都是 HDFS 最常用的 Shell 命令,分别用来查看 HDFS 文件系统的目录结构、上传和下载数据、创建文件等。这 3 个命令既有联系有又区别。

- (1) hadoop fs: 适用于任何不同的文件系统,例如本地文件系统和 HDFS 文件系统。
- (2) hadoop dfs: 只能适用于 HDFS 文件系统。
- (3) hdfs dfs: 跟 hadoop dfs 命令的作用一样,也只能适用于 HDFS 文件系统。 在本书中,统一使用 hdfs dfs 命令对 HDFS 进行操作。

# 4.1.1 查看命令使用方法

登录 Linux 系统,打开一个终端,首先启动 Hadoop,命令如下:

\$cd /usr/local/hadoop
\$./sbin/start-dfs.sh

可以在终端输入如下命令,查看 hdfs dfs 总共支持哪些操作。

\$cd /usr/local/hadoop

\$./bin/hdfs dfs

上述命令执行后,会显示类似如下的结果(这里只列出部分命令):

```
[-appendToFile ••• ]
[-cat [-ignoreCrc] ···]
[-checksum ···]
[-chgrp [-R] GROUP PATH ...]
[-chmod [-R]< MODE[, MODE] ··· | OCTALMODE> PATH ··· ]
[-chown [-R] [OWNER] [: [GROUP]] PATH *** ]
[-copyFromLocal [-f] [-p] [-l] ··· ]
[-copyToLocal [-p] [-ignoreCrc] [-crc] ··· ]
[-count [-q] [-h] •••]
[-cp [-f] [-p | -p[topax]] ··· ]
[-createSnapshot []]
[-deleteSnapshot]
[-df [-h] [ ••• ]]
[-du [-s] [-h] •••]
[-expunge]
[-find •••]
[-get [-p] [-ignoreCrc] [-crc] ··· ]
[-getfacl [-R]]
[-getfattr [-R] {-n name | -d} [-e en]]
[-getmerge [-nl]]
[-help [cmd ···]]
[-ls [-d] [-h] [-R] [ ••• ]]
[-mkdir [-p] •••]
[-moveFromLocal · · · ]
[-moveToLocal]
[-mv ••• ]
[-put [-f] [-p] [-1] ··· ]
```

可以看出,hdfs dfs 命令的统一格式是类似 hdfs dfs -ls 这种形式,即在"-"后面跟上具体的操作。

可以查看某个命令的作用,例如,当需要查询 put 命令的具体用法时,可以采用如下命令:

```
$./bin/hdfs dfs - help put
```

#### 输出的结果如下:

```
-put [-f] [-p] [-l] ...:
Copy files from the local file system into fs. Copying fails if the file already exists,
unless the -f flag is given.
Flags:
-p Preserves access and modification times, ownership and the mode.
```

- -f Overwrites the destination if it already exists.
- -1 Allow DataNode to lazily persist the file to disk. Forces replication factor of 1. This flag will result in reduced durability. Use with care.

# 4.1.2 HDFS 目录操作

### 1. 目录操作

需要注意的是, Hadoop 系统安装好以后, 第一次使用 HDFS 时, 需要首先在 HDFS 中创建用户目录。本书全部采用 hadoop 用户登录 Linux 系统, 因此, 需要在 HDFS 中为 hadoop 用户创建一个用户目录, 命令如下:

\$cd /usr/local/hadoop

\$./bin/hdfs dfs - mkdir - p /user/hadoop

该命令中表示在 HDFS 中创建一个/user/hadoop 目录,-mkdir 是创建目录的操作,-p表示如果是多级目录,则父目录和子目录一起创建,这里/user/hadoop 就是一个多级目录,因此必须使用参数-p,否则会出错。

/user/hadoop 目录就成为 hadoop 用户对应的用户目录,可以使用如下命令显示 HDFS 中与当前用户 hadoop 对应的用户目录下的内容:

\$./bin/hdfs dfs - ls.

该命令中,-ls 表示列出 HDFS 某个目录下的所有内容,"."表示 HDFS 中的当前用户目录,也就是/user/hadoop目录,因此,上面的命令和下面的命令是等价的:

\$./bin/hdfs dfs - ls /user/hadoop

如果要列出 HDFS 上的所有目录,可以使用如下命令:

\$./bin/hdfs dfs - ls

下面可以使用如下命令创建一个 input 目录:

\$./bin/hdfs dfs - mkdir input

在创建个 input 目录时,采用了相对路径形式,实际上,这个 input 目录创建成功以后,它在 HDFS 中的完整路径是/user/hadoop/input。如果要在 HDFS 的根目录下创建一个名称为 input 的目录,则需要使用如下命令:

\$./bin/hdfs dfs -mkdir /input

可以使用 rm 命令删除一个目录,例如,可以使用如下命令删除刚才在 HDFS 中创建

的/input 目录(不是/user/hadoop/input 目录):

\$./bin/hdfs dfs - rm - r /input

上面命令中,-r 参数表示如果删除/input 目录及其子目录下的所有内容,如果要删除的一个目录包含了子目录,则必须使用-r 参数,否则会执行失败。

#### 2. 文件操作

在实际应用中,经常需要从本地文件系统向 HDFS 中上传文件,或者把 HDFS 中的文件下载到本地文件系统中。

首先使用 vim 编辑器,在本地 Linux 文件系统的/home/hadoop/目录下创建一个文件 myLocalFile.txt,里面可以随意输入一些单词,例如,输入如下三行:

Hadoop

Spark

XMU DBLAB

然后可以使用如下命令把本地文件系统的/home/hadoop/myLocalFile.txt 上传到HDFS中的当前用户目录的 input 目录下,也就是上传到 HDFS 的/user/hadoop/input/目录下:

\$./bin/hdfs dfs - put /home/hadoop/myLocalFile.txt input

可以使用 ls 命令查看一下文件是否成功上传到 HDFS 中,具体如下:

\$./bin/hdfs dfs - ls input

该命令执行后会显示类似如下的信息:

Found 1 items

-rw-r--r-- 1 hadoop supergroup

36 2017-01-02 23:55 input/ myLocalFile.txt

下面使用如下命令查看 HDFS 中的 myLocalFile. txt 这个文件的内容:

\$./bin/hdfs dfs - cat input/myLocalFile.txt

下面把 HDFS 中的 myLocalFile. txt 文件下载到本地文件系统中的"/home/hadoop/下载/"这个目录下,命令如下:

\$./bin/hdfs dfs - get input/myLocalFile.txt /home/hadoop/下载

可以使用如下命令,从本地文件系统查看下载下来的文件 myLocalFile. txt:

```
$cd ~
$cd 下载
$ls
$cat myLocalFile.txt
```

最后了解一下如何把文件从 HDFS 中的一个目录复制到 HDFS 中的另外一个目录。例如,如果要把 HDFS 的/user/hadoop/input/myLocalFile.txt 文件,复制到 HDFS 的另外一个目录/input 中(注意,这个 input 目录位于 HDFS 根目录下),可以使用如下命令:

```
$./bin/hdfs dfs - cp input/myLocalFile.txt /input
```

# 4.2 利用 HDFS 的 Web 管理界面

HDFS 提供了 Web 管理界面,可以很方便地查看 HDFS 相关信息。需要在 Linux 系统中(不是 Windows 系统)打开自带的 Firefox 浏览器,在浏览器地址栏中输入 http://localhost:50070,按 Enter 键后就可以看到如图 4-1 所示的 HDFS 的 Web 管理界面。

host: 50070/c	ifshealth.htm	ml#tab-overvie	w			(で) (2、捜索
Hadoop	Overview	Datanodes	Datanode Volume Failures	Snapshot	Startup Progress	Utilities -
OVER	view '	localhost:(	0000' (active)			
Over	view 1		9000' (active) on Jan 02 20:00:40 CST 2017			
	view 1	Мо		c56de536e6ce	557a	
Started:	view 1	Mo 2.7	n Jan 02 20:00:40 CST 2017			
Started: Version:	view 1	Mo 2.7 201	n Jan 02 20:00:40 CST 2017 .1, r15ecc87ccf4a0228f35af08f	n (detached fr		

图 4-1 HDFS 的 Web 管理界面

在 HDFS 的 Web 管理界面中,包含了 Overview、Datanodes、Datanode Volume Failures、Snapshot、Startup Progress 和 Utilities 等菜单选项,单击每个菜单选项可以进入相应的管理界面,查询各种详细信息。

# 4.3 HDFS 编程实践

Hadoop 采用 Java 语言开发,提供了 Java API 与 HDFS 进行交互。上面介绍的 Shell 命令,在执行时实际上会被系统转换成 Java API 调用。Hadoop 官方网站提供了完整的 Hadoop API 文档(http://hadoop.apache.org/docs/stable/api/),想要深入学习 Hadoop 编程,可以访问 Hadoop 官网查看各个 API 的功能和用法。本书只介绍基础的 HDFS 编程。

为了提高程序编写和调试效率,本书采用 Eclipse 工具编写 Java 程序。

# 4.3.1 在 Eclipse 中创建项目

首先请参照第2章的内容完成 Eclipse 的安装;然后启动 Eclipse。当 Eclipse 启动以后,会弹出如图 4-2 所示的界面,提示设置工作空间(workspace)。

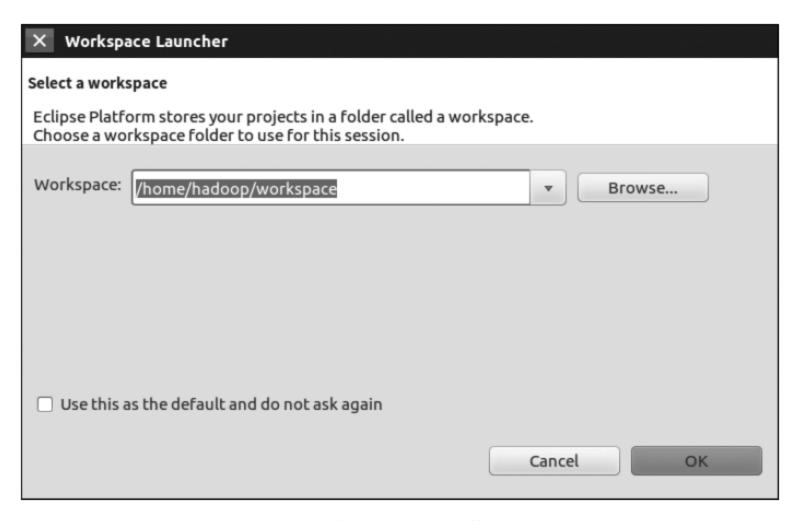


图 4-2 Eclipse 启动以后的工作空间设置界面

可以直接采用默认的设置/home/hadoop/workspace,单击 OK 按钮。可以看出,由于当前是采用 hadoop 用户登录了 Linux 系统,因此,默认的工作空间目录位于 hadoop 用户目录/home/hadoop下。

Eclipse 启动以后,会呈现如图 4-3 所示的界面。

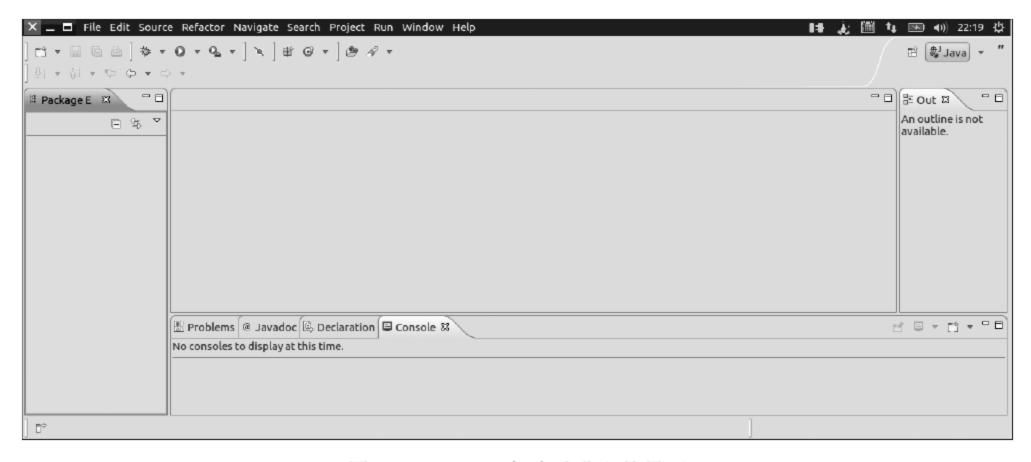


图 4-3 Eclipse 启动后进入的界面

选择 File→New→Java Project 命令,开始创建一个 Java 工程,会弹出如图 4-4 所示的界面。

在 Project name 后面输入工程名称 HDFSExample,选中 Use default location 复选框,

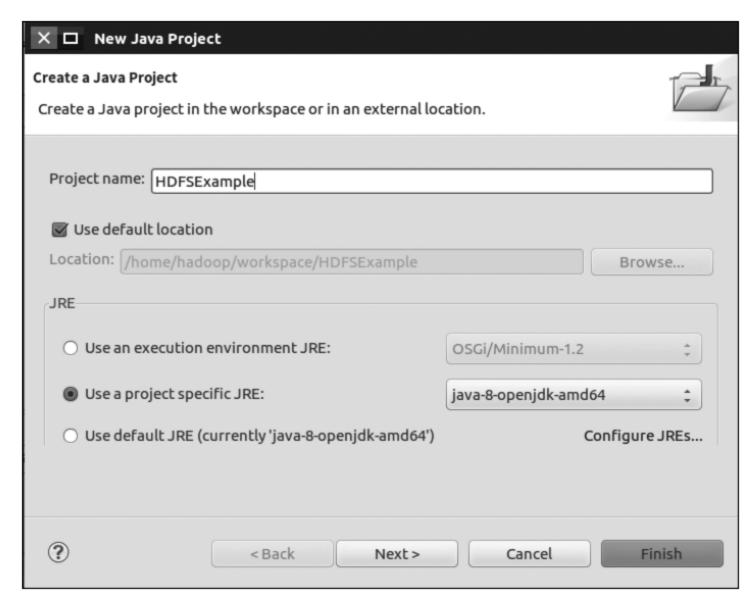


图 4-4 新建 Java 工程界面

将 Java 工程的所有文件都保存到/home/hadoop/workspace/HDFSExample 目录下。在 JRE 选项卡中,可以选择当前的 Linux 系统中已经安装好的 JDK,例如 java-8-openjdk-amd64;然后单击界面底部的 Next 按钮,进入下一步设置。

# 4.3.2 为项目添加需要用到的 JAR 包

进入下一步设置以后,会弹出如图 4-5 所示的界面。

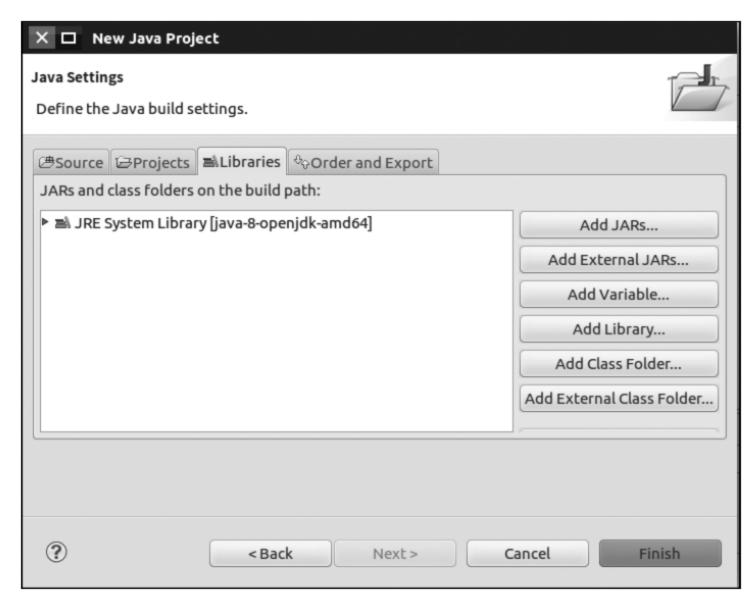


图 4-5 添加 JAR 包界面

需要在这个界面中加载该 Java 工程所需要用到的 JAR 包,这些 JAR 包中包含了可以访问 HDFS 的 Java API。这些 JAR 包都位于 Linux 系统的 Hadoop 安装目录下,对于本书而言,就是在/usr/local/hadoop/share/hadoop 目录下。单击界面中的 Libraries 选项卡,然后单击界面右侧的 Add External JARs 按钮,会弹出如图 4-6 所示的界面。

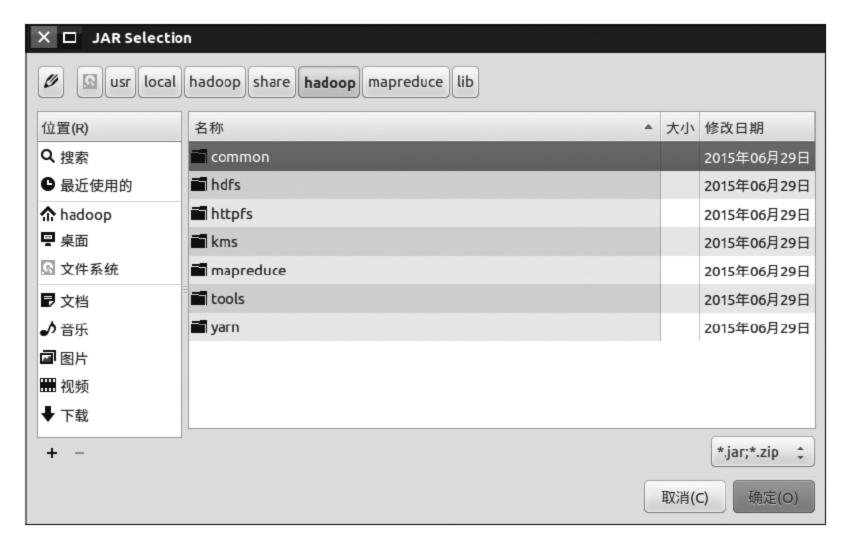


图 4-6 JAR 包选择界面

在该界面中,上面有一排目录按钮(即 usr、local、hadoop、share、hadoop、mapreduce 和 lib),当单击某个目录按钮时,就会在下面列出该目录的内容。

为了编写一个能够与 HDFS 交互的 Java 应用程序,一般需要向 Java 工程中添加以下 JAR 包:

- (1) /usr/local/hadoop/share/hadoop/common 目录下的 hadoop-common-2. 7. 1. jar 和 haoop-nfs-2. 7. 1. jar。
  - (2) /usr/local/hadoop/share/hadoop/common/lib 目录下的所有 JAR 包。
- (3) /usr/local/hadoop/share/hadoop/hdfs 目录下的 haoop-hdfs-2.7.1. jar 和 haoop-hdfs-1.7.1. jar。
  - (4) /usr/local/hadoop/share/hadoop/hdfs/lib 目录下的所有 JAR 包。

例如,如果要把/usr/local/hadoop/share/hadoop/common 目录下的 hadoop-common-2.7.1. jar 和 haoop-nfs-2.7.1. jar 添加到当前的 Java 工程中,可以在界面中单击目录按钮,进入到 common 目录;然后界面会显示出 common 目录下的所有内容(见图 4-7)。

在界面中单击选中 hadoop-common-2.7.1. jar 和 haoop-nfs-2.7.1. jar,然后单击界面右下角的"确定"按钮,就可以把这两个 JAR 包增加到当前 Java 工程中,出现的界面如图 4-8 所示。

从这个界面中可以看出,hadoop-common-2.7.1. jar 和 haoop-nfs-2.7.1. jar 已经被添加到当前 Java 工程中;然后按照类似的操作方法,可以再次单击 Add External JARs 按钮,把剩余的其他 JAR 包都添加进来。需要注意的是,当需要选中某个目录下的所有 JAR 包时,可以使用 Ctrl+A 键进行全选操作。全部添加完毕以后,就可以单击界面右下角的

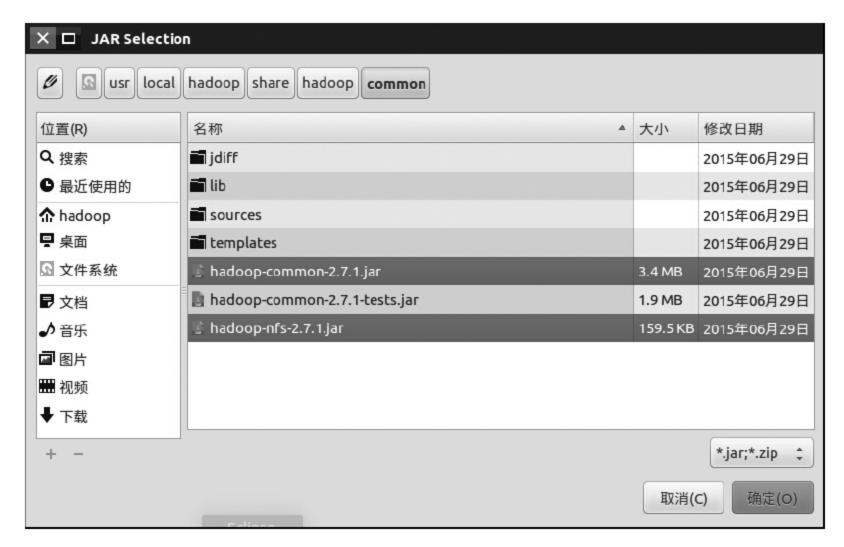


图 4-7 选择 common 目录下的 JAR 包

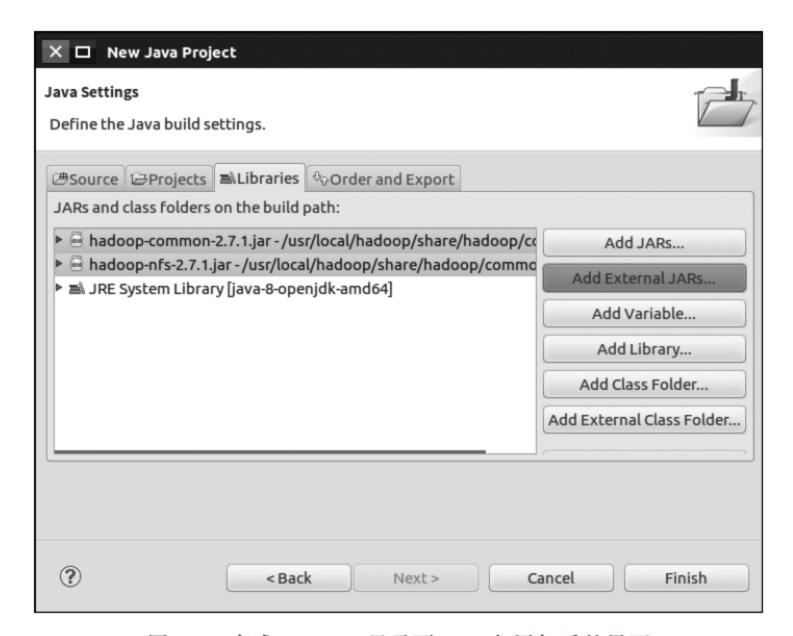


图 4-8 完成 common 目录下 JAR 包添加后的界面

Finish 按钮,完成 Java 工程 HDFSExample 的创建。

#### 4.3.3 编写 Java 应用程序

下面编写一个 Java 应用程序,用来检测 HDFS 中是否存在一个文件。

在 Eclipse 工作界面左侧的 Package Explorer 面板中 (见图 4-9)找到刚才创建好的工程名称 HDFSExample,然 后在该工程名称上右击,在弹出的菜单中选择 New→

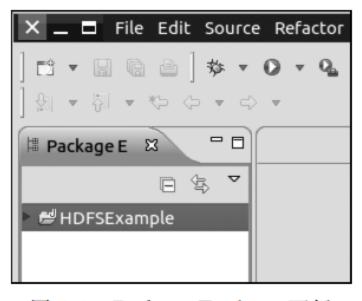


图 4-9 Package Explorer 面板

Class命令。

选择 New→Class 命令以后会出现如图 4-10 所示的界面。

X   New Java Class						
Java Class  A The use of the def	ault package is discouraged.					
Source folder:	HDFSExample/src	Browse				
Package:	(default)	Browse				
☐ Enclosing type:		Browse				
Name: Modifiers: Superclass:	HDFSFileIfExist ● public	Browse				
Interfaces:		Add				
?	Cancel	Finish				

图 4-10 新建 Java Class 界面

在该界面中,只需要在 Name 后面输入新建的 Java 类文件的名称,这里采用名称 HDFSFileIfExist,其他都可以采用默认设置;然后单击界面右下角的 Finish 按钮,出现如图 4-11 所示的界面。

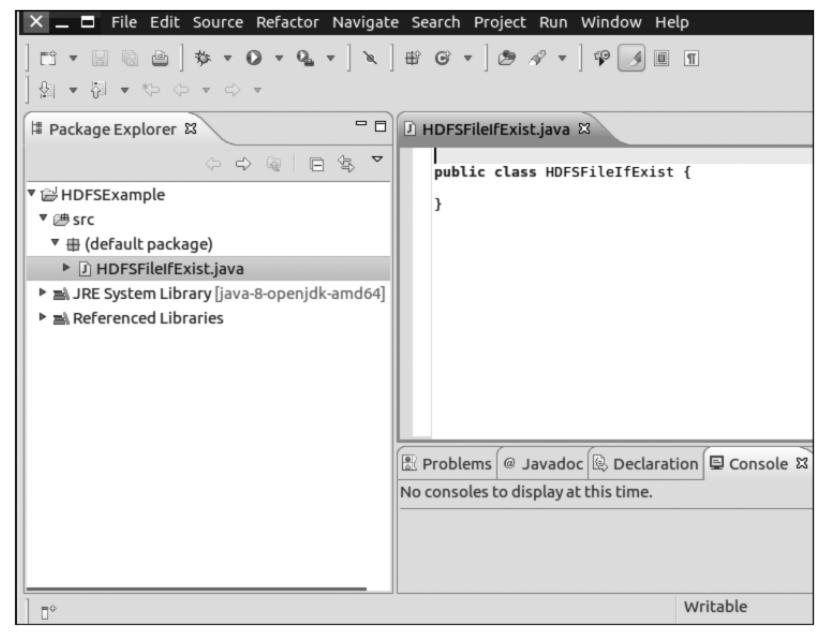


图 4-11 新建一个类文件以后的 Eclipse 界面

可以看出, Eclipse 自动创建了一个名为 HDFSFileIfExist. java 的源代码文件, 请在该文件中输入以下代码:

```
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.FileSystem;
import org.apache.hadoop.fs.Path;
public class HDFSFileIfExist {
    public static void main(String[] args){
        try{
             String fileName= "test";
            Configuration conf=new Configuration();
             conf.set("fs.defaultFS", "hdfs://localhost:9000");
            conf.set("fs.hdfs.impl", "org.apache.hadoop.hdfs.
            DistributedFileSystem");
            FileSystem fs=FileSystem.get(conf);
             if (fs.exists (new Path (fileName))) {
                System.out.println("文件存在");
             }else{
                System.out.println("文件不存在");
             }
        }catch (Exception e) {
            e.printStackTrace();
```

上述代码也可以直接从本书官网的"下载专区"中下载,单击进入下载专区后,在"代码"这个文件夹中,找到"第4章"文件夹,把该文件夹下的 HDFSFileIfExist. java 文件下载到本地。

该程序用来测试 HDFS 中是否存在一个文件,其中有一行代码:

```
String fileName="test"
```

这行代码给出了需要被检测的文件名称是 test,没有给出路径全称,表示是采用了相对路径,实际上就是测试当前登录 Linux 系统的用户 hadoop,在 HDFS 中对应的用户目录下是否存在 test 文件,也就是测试 HDFS 中的/user/hadoop/目录下是否存在 test 文件。

# 4.3.4 编译运行程序

在开始编译运行程序之前,请一定确保 Hadoop 已经启动运行,如果还没有启动,需要打开一个 Linux 终端,输入以下命令启动 Hadoop:

```
$cd /usr/local/hadoop
$./sbin/start-dfs.sh
```

现在就可以编译运行上面编写的代码。可以直接单击 Eclipse 工作界面上部的运行程序的快捷按钮,当把鼠标移动到该按钮上时,在弹出的菜单中选择 Run As,继续在弹出来的菜单中选择 Java Application,如图 4-12 所示。

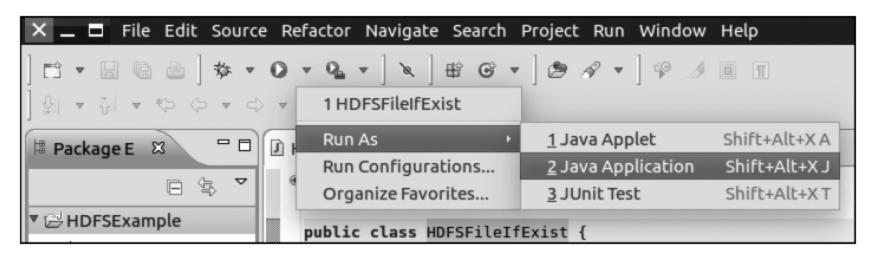


图 4-12 运行程序界面

然后会弹出如图 4-13 所示的界面。

HDFSFileIfExist			×
Natching items:			
S HDFSFileIfExist - (default p	scrage)		
⊞ HDFSExample/bin - (defau	t package)		

图 4-13 Select Java Application 界面

在该界面中需要在 Select type 下面的文本框中输入 HDFSFileIfExist, Eclipse 就会自动找到相应的类 HDFSFileIfExist-(default package)(注意: 这个类在后面的导出 JAR 包操作中的 Launch configuration 中会被用到);然后单击界面右下角的 OK 按钮,开始运行程序。程序运行结束后,会在底部的 Console 面板中显示运行结果信息(见图 4-14)。由于目前 HDFS 的/user/hadoop 目录下还没有 test 文件,因此,程序运行结果是"文件不存在"。

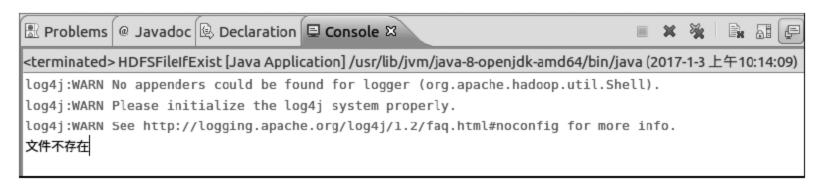


图 4-14 运行结果信息

同时, Console 面板中还会显示一些类似"log4j: WARN···"的警告信息,可以不用理会。

#### 4.3.5 应用程序的部署

下面介绍如何把 Java 应用程序生成 JAR 包,部署到 Hadoop 平台上运行。首先,在 Hadoop 安装目录下新建一个名称为 myapp 的目录,用来存放所编写的 Hadoop 应用程序,可以在 Linux 的终端中执行如下命令:

\$cd /usr/local/hadoop
\$mkdir myapp

然后在 Eclipse 工作界面左侧的 Package Explorer 面板中,在工程名称 HDFSExample 上右击,在弹出的菜单中选择 Export,如图 4-15 所示。

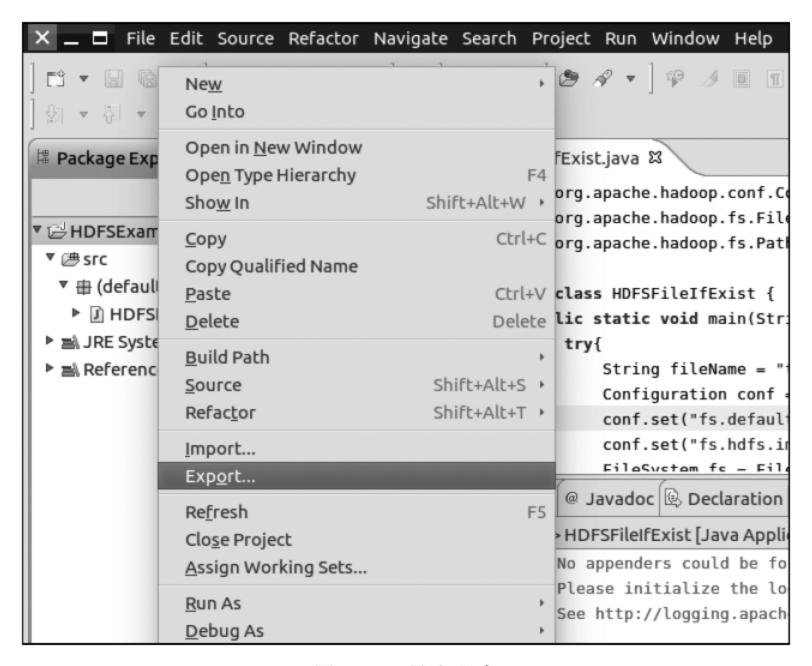


图 4-15 导出程序

最后会弹出如图 4-16 所示的界面。

在该界面中选择 Runnable JAR file,然后单击 Next 按钮,弹出如图 4-17 所示的界面。在该界面中,Launch configuration 用于设置生成的 JAR 包被部署启动时运行的主类,需要 在下拉列表中选择刚才配置的类 HDFSFileIfExist-HDFSExample。在 Export destination 中需要设置 JAR 包要输出保存到哪个目录,例如,这里设置为/usr/local/hadoop/myapp/HDFSExample. jar。在 Library handling 下面选择 Extract required

可以忽略该界面的提示信息,直接单击界面右下角的 OK 按钮,启动打包过程。打包过程结束后,会出现一个警告信息界面,如图 4-19 所示。

libraries into generated JAR,然后单击 Finish 按钮,会出现如图 4-18 所示的界面。

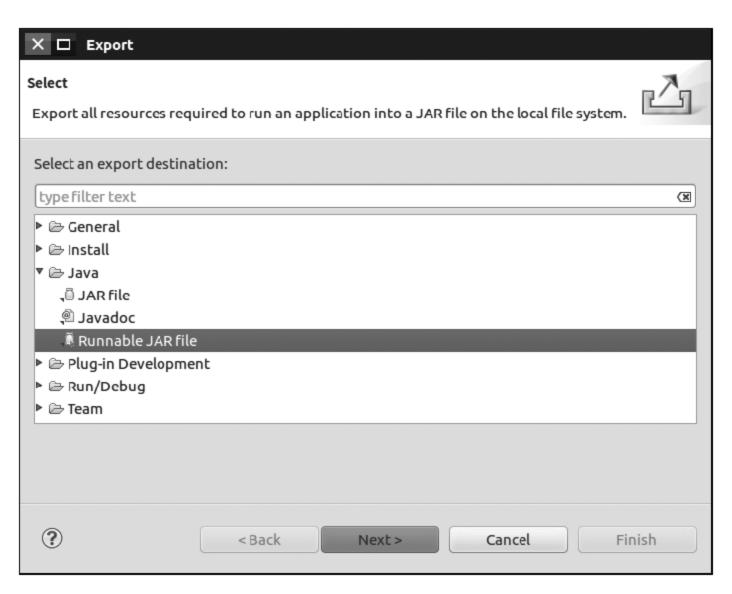


图 4-16 导出程序时选择 Runnable JAR file

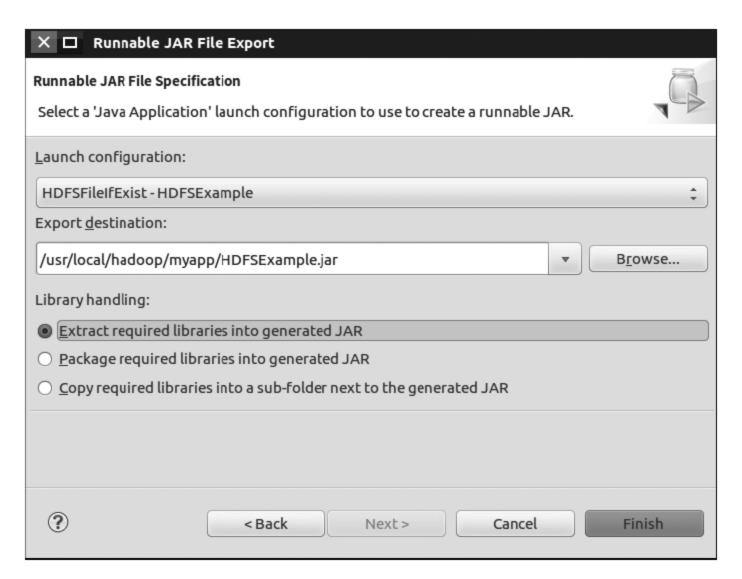


图 4-17 导出程序设置界面

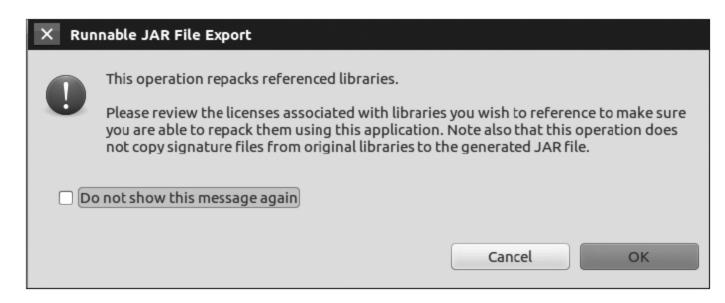


图 4-18 提示信息

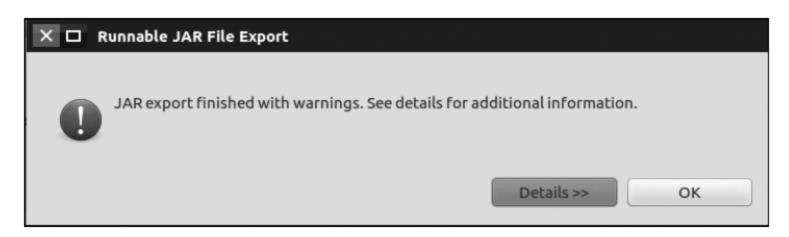


图 4-19 警告信息

可以忽略该界面的警告信息,直接单击界面右下角的 OK 按钮。至此,已经顺利把 HDFSExample 工程打包生成了 HDFSExample.jar。可以到 Linux 系统中查看一下生成的 HDFSExample.jar 文件,可以在 Linux 的终端中执行如下命令:

```
$cd /usr/local/hadoop/myapp
$ls
```

可以看到,/usr/local/hadoop/myapp 目录下已经存在一个 HDFSExample. jar 文件。 现在,就可以在 Linux 系统中,使用 hadoop jar 命令运行程序,命令如下:

```
$cd /usr/local/hadoop
$./bin/hadoop jar ./myapp/HDFSExample.jar
```

命令执行结束后,会在屏幕上显示执行结果"文件不存在"。

至此,检测 HDFS 文件是否存在的程序,就顺利部署完成了。本书在教程官网的"下载专区"的"代码"目录的"第4章"子目录下,还提供了另外两个代码文件供参考,即 HDFSCreateFile. java 和 HDFSReadFile. java,可以下载到本地,按照上述介绍的方法,分别撰写 Java 程序,向 HDFS 写入一个文件和从 HDFS 中读取一个文件。

# 4.4 本章小结

大数据时代必须解决海量数据的高效存储问题,为此,谷歌开发了分布式文件系统GFS,通过网络实现文件在多台机器上的分布式存储,较好地满足了大规模数据存储的需求。HDFS是针对GFS的开源实现,它是 Hadoop 两大核心组成部分之一。

在很多情形下,需要使用 Shell 命令来操作 HDFS,因此,本章介绍了 HDFS 操作常用的 Shell 命令,包括目录操作命令和文件操作命令等。同时,还介绍了如何利用 HDFS 的 Web 管理界面,以可视化的方式查看 HDFS 的相关信息。最后,本章详细介绍了如何使用 Eclipse 开发操作 HDFS 的 Java 应用程序。本章介绍的 Eclipse 开发方法,为后续章节的编程开发提供了很好的借鉴。



# HBase 的安装和基础编程

HBase 是一个高可靠、高性能、面向列、可伸缩的分布式数据库,是谷歌 BigTable 的开源实现,主要用来存储非结构化和半结构化的松散数据。HBase 的目标是处理非常庞大的表,可以通过水平扩展的方式,利用廉价的计算机集群处理由超过 10 亿行数据和数百万列元素组成的数据表。Hadoop 安装以后,不包含 HBase 组件,需要另外安装。

本章首先介绍 HBase 的安装方法,并介绍 HBase 的两种不同模式的配置方法,包括单机模式和伪分布式模式,然后介绍一些操作 HBase 的常用的 Shell 命令,最后,介绍如何使用 Eclipse 开发可以操作 HBase 数据库的 Java 应用程序。

# 5.1 安装 HBase

本节介绍 HBase 的安装方法,包括下载安装文件、配置环境变量、添加用户权限等。

# 5.1.1 下载安装文件

HBase 是 Hadoop 生态系统中的一个组件,但是,Hadoop 安装以后,本身并不包含 HBase,因此,需要单独安装 HBase。登录 Linux 系统,在 Linux 系统(不是 Windows 系统)中打开火狐浏览器,访问本书官网的"下载专区",在"软件"目录下下载 HBase 安装文件 hbase-1.1.5-bin. tar. gz。火狐浏览器会默认把下载文件都保存到当前用户的下载目录,由于本书全部采用 hadoop 用户登录 Linux 系统,所以,hbase-1.1.5-bin. tar. gz 文件会被保存到/home/hadoop/下载/目录下。

需要注意的是,如果是在 Windows 系统下面下载安装文件 hbase-1.1.5-bin. tar. gz,则需要通过 FTP 软件上传到 Linux 系统的"/home/hadoop/下载/"目录下,这个目录是本书所有安装文件的中转站。

下载完安装文件以后,需要对文件进行解压。按照 Linux 系统使用的默认规范,用户安装的软件一般都是存放在/usr/local/目录下。使用 hadoop 用户登录 Linux 系统,打开一个终端,执行如下命令:

\$sudo tar -zxf ~/下载/hbase-1.1.5-bin.tar.gz -C /usr/local

将解压的文件名 hbase-1.1.5 改为 hbase,以方便使用,命令如下:

\$sudo mv /usr/local/hbase-1.1.5 /usr/local/hbase

## 5.1.2 配置环境变量

将 HBase 安装目录下的 bin 目录(即/usr/local/hbase/bin)添加到系统的 PATH 环境变量中,这样,每次启动 HBase 时就不需要到/usr/local/hbase 目录下执行启动命令,方便 HBase 的使用。使用 vim 编辑器打开~/. bashrc 文件,命令如下:

\$vim ~/.bashrc

打开. bashrc 文件以后,可以看到,已经存在如下所示的 PATH 环境变量的配置信息,因为,之前在第 3 章安装配置 Hadoop 时,已经为 Hadoop 添加了 PATH 环境变量的配置信息:

export PATH= \$PATH:/usr/local/hadoop/sbin:/usr/local/hadoop/bin

这里需要把 HBase 的 bin 目录/usr/local/hbase/bin 追加到 PATH 中。当要在 PATH 中继续加入新的路径时,只要用英文冒号":"隔开,把新的路径加到后面即可,追加后的结果如下:

export PATH= \$PATH:/usr/local/hadoop/sbin:/usr/local/hadoop/bin:/usr/
local/hbase/bin

添加后执行如下命令使设置生效:

\$source ~/.bashrc

# 5.1.3 添加用户权限

需要为当前登录 Linux 系统的 hadoop 用户添加访问 HBase 目录的权限,将 HBase 安装目录下的所有文件的所有者改为 hadoop,命令如下:

\$cd /usr/local
\$sudo chown -R hadoop ./hbase

# 5.1.4 查看 HBase 版本信息

可以通过如下命令查看 HBase 版本信息,以确认 HBase 已经安装成功:

\$/usr/local/hbase/bin/hbase version

执行上述命令以后,如果出现如图 5-1 所示的信息,则说明安装成功。

```
hadoop@dblab-VirtualBox:/usr/local/hadoop$ cd /usr/local/hbase hadoop@dblab-VirtualBox:/usr/local/hbase$ ./bin/hbase version 2017-02-04 19:53:59,353 INFO [main] util.VersionInfo: HBase 1.1.5 2017-02-04 19:53:59,362 INFO [main] util.VersionInfo: Source code repository git://diocles.local/Volumes/hbase-1.1.5/hbase revision=239b80456118175b340b2e562a5568b 5c744252e 2017-02-04 19:53:59,362 INFO [main] util.VersionInfo: Compiled by ndimiduk on Sun May 8 20:29:26 PDT 2016 2017-02-04 19:53:59,362 INFO [main] util.VersionInfo: From source with checksum 7 ad8dc6c5daba19e4aab081181a2457d
```

图 5-1 查看 HBase 版本信息

# 5.2 HBase 的配置

HBase 有 3 种运行模式,即单机模式、伪分布式模式和分布式模式。

- (1) 单机模式:采用本地文件系统存储数据。
- (2) 伪分布式模式:采用伪分布式模式的 HDFS 存储数据。
- (3) 分布式模式:采用分布式模式的 HDFS 存储数据。

本书仅介绍单机模式和伪分布式模式。

在进行 HBase 配置之前,需要确认已经安装了 3 个组件: JDK、Hadoop、SSH。 HBase 单机模式不需要安装 Hadoop,伪分布式模式和分布式模式需要安装 Hadoop。 JDK、Hadoop 和 SSH 的安装方法,已经在第 3 章中做了详细介绍,如果已经按照第 3 章的方法安装了 Hadoop,则这里不需要另外安装 JDK、Hadoop 和 SSH。

#### 5.2.1 单机模式配置

1. 配置 hbase-env.sh 文件

使用 vim 编辑器打开/usr/local/hbase/conf/hbase-env. sh,命令如下:

\$vim /usr/local/hbase/conf/hbase-env.sh

打开 hbase-env. sh 文件以后,需要在 hbase-env. sh 文件中配置 JAVA 环境变量,在第 3 章中已经配置了 JAVA\_HOME=/usr/lib/jvm/java-7-openjdk-amd64,这里可以直接复制该配置信息到 hbase-env. sh 文件中。此外,还需要添加 Zookeeper 配置信息,配置 HBASE\_MANAGES\_ZK 为 true,表示由 HBase 自己管理 Zookeeper,不需要单独的 Zookeeper,由于 hbase-env. sh 文件中本来就存在这些变量的配置,因此,只需要删除前面的注释符号#并修改配置内容即可,修改后的 hbase-env. sh 文件应该包含如下两行信息:

```
export JAVA_HOME=/usr/lib/jvm/java-7-openjdk-amd64 export HBASE MANAGES ZK=true
```

修改完成以后,保存 hbase-env. sh 文件并退出 vim 编辑器。

#### 2. 配置 hbase-site.xml 文件

使用 vim 编辑器打开并编辑/usr/local/hbase/conf/hbase-site.xml 文件,命令如下:

```
$vim /usr/local/hbase/conf/hbase-site.xml
```

在 hbase-site. xml 文件中,需要设置属性 hbase. rootdir,用于指定 HBase 数据的存储位置,如果没有设置,则 hbase. rootdir 默认为/tmp/hbase-\$ {user. name},这意味着每次重启系统都会丢失数据。这里把 hbase. rootdir 设置为 HBase 安装目录下的 hbase-tmp 文件夹,即/usr/local/hbase/hbase-tmp,修改后的 hbase-site. xml 文件中的配置信息如下:

保存 hbase-site. xml 文件,并退出 vim 编辑器。

#### 3. 启动并运行 HBase

现在就可以测试运行 HBase,命令如下:

```
$cd /usr/local/hbase
$bin/start-hbase.sh #启动 HBase
```

\$bin/hbase shell #进入 HBase Shell 命令行模式

进入 HBase Shell 命令行模式以后,用户可以通过输入 Shell 命令操作 HBase 数据库。成功启动 HBase 后会出现如图 5-2 所示的界面。

```
hadoop@dblab-VirtualBox:/usr/local/hbase$ ./bin/hbase shell
SLF4J: Class path contains multiple SLF4J bindings.
SLF4J: Found binding in [jar:file:/usr/local/hbase/lib/slf4j-log4j12-1.7.5.jar!/org/slf4j/impl/StaticLoggerBinder.class]
SLF4J: Found binding in [jar:file:/usr/local/hadoop/share/hadoop/common/lib/slf4j-log4j12-1.7.10.jar!/org/slf4j/impl/StaticLoggerBinder.class]
SLF4J: See http://www.slf4j.org/codes.html#multiple_bindings for an explanation.
SLF4J: Actual binding is of type [org.slf4j.impl.Log4jLoggerFactory]
HBase Shell; enter 'help<RETURN>' for list of supported commands.
Type "exit<RETURN>" to leave the HBase Shell
Version 1.1.5, r239b80456118175b340b2e562a5568b5c744252e, Sun May 8 20:29:26 PDT 2016
hbase(main):001:0>
```

图 5-2 进入 HBase Shell 模式

最后可以使用如下命令停止 HBase 运行:

```
$bin/stop-hbase.sh
```

需要说明的是,如果在操作 HBase 的过程中发生错误,可以查看{HBASE\_HOME}目录(即/usr/local/hbase)下的 logs 子目录中的日志文件,来寻找可能的错误原因,然后搜索网络资料寻找相关解决方案。

#### 5.2.2 伪分布式配置

#### 1. 配置 hbase-env.sh 文件

使用 vim 编辑器打开/usr/local/hbase/conf/hbase-env. sh,命令如下:

\$vim /usr/local/hbase/conf/hbase-env.sh

打开 hbase-env. sh 文件以后,需要在 hbase-env. sh 文件中配置 JAVA\_HOME、HBASE\_CLASSPATH 和 HBASE\_MANAGES\_ZK。其中,HBASE\_CLASSPATH 设置为本机 Hadoop 安装目录下的 conf 目录(即/usr/local/hadoop/conf)。JAVA\_HOME 和HBASE\_MANAGES\_ZK 的配置方法和上面单机模式的配置方法相同。修改后的 hbase-env. sh 文件应该包含如下 3 行信息:

```
export JAVA_HOME=/usr/lib/jvm/java-7-openjdk-amd64
export HBASE_CLASSPATH=/usr/local/hadoop/conf
export HBASE_MANAGES_ZK=true
```

修改完成以后,保存 hbase-env. sh 文件并退出 vim 编辑器。

#### 2. 配置 hbase-site.xml 文件

使用 vim 编辑器打开并编辑/usr/local/hbase/conf/hbase-site. xml 文件,命令如下:

\$vim /usr/local/hbase/conf/hbase-site.xml

在 hbase-site. xml 文件中,需要设置属性 hbase. rootdir,用于指定 HBase 数据的存储位置。在 HBase 伪分布式模式中,使用伪分布式模式的 HDFS 存储数据,因此,需要把 hbase. rootdir 设置为 HBase 在 HDFS 上的存储路径。根据第 3 章 Hadoop 伪分布式模式的配置可以知道, HDFS 的访问路径为 hdfs://localhost:9000/,因为,这里设置 hbase. rootdir 为 hdfs://localhost:9000/hbase。此外,由于采用了伪分布式模式,因此,还需要将属性 hbase. cluter. distributed 设置为 true。修改后的 hbase-site. xml 文件中的配置信息如下:

<name>hbase.cluster.distributed

<value>true</value>

</configuration>

保存 hbase-site. xml 文件,并退出 vim 编辑器。

#### 3. 启动运行 HBase

首先登录 SSH,由于之前在第3章中已经设置了无密码登录,因此这里不需要密码;然后切换至/usr/local/hadoop,启动 Hadoop,让 HDFS 进入运行状态,从而可以为 HBase 存储数据,具体命令如下:

\$ssh localhost

\$cd /usr/local/hadoop

\$./sbin/start-dfs.sh

输入命令 jps,如果能够看到 NameNode、DataNode 和 SecondaryNameNode 这 3 个进程,则表示已经成功启动 Hadoop。

然后启动 HBase,命令如下:

\$cd /usr/local/hbase

\$bin/start-hbase.sh

输入命令 jps,如果出现以下进程,则说明 HBase 启动成功:

Jps

HMaster

**HQuorumPeer** 

NameNode

HRegionServer

SecondaryNameNode

DataNode

现在就可以进入 HBase Shell 模式,命令如下:

\$bin/hbaseshell

#进入 HBase Shell 命令行模式

进入 HBase Shell 命令行模式以后,用户可以通过输入 Shell 命令操作 HBase 数据库。

#### 4. 停止运行 HBase

最后可以使用如下命令停止 HBase 运行:

\$bin/stop-hbase.sh

如果在操作 HBase 的过程中发生错误,可以查看{HBASE\_HOME}目录(即/usr/local/hbase)下的 logs 子目录中的日志文件,来寻找可能的错误原因。

关闭 HBase 以后,如果不再使用 Hadoop,就可以运行如下命令关闭 Hadoop:

\$cd /usr/local/hadoop
\$./sbin/stop-dfs.sh

最后需要注意的是,启动关闭 Hadoop 和 HBase 的顺序一定是:启动 Hadoop→启动 HBase→关闭 HBase→关闭 Hadoop。

# 5.3 HBase 常用 Shell 命令

在使用具体的 Shell 命令操作 HBase 数据之前,需要首先启动 Hadoop,然后再启动 HBase 和 HBase Shell,进入 Shell 命令提示符状态,具体命令如下:

\$cd /usr/local/hadoop

\$./sbin/start-dfs.sh

\$cd /usr/local/hbase

- \$./bin/start-hbase.sh
- \$./bin/hbase shell

# 5.3.1 在 HBase 中创建表

假设这里要创建一个表 student,该表包含 Sname、Ssex、Sage、Sdept、course 等字段。需要注意的是,在关系型数据库(如 MySQL)中,需要首先创建数据库,然后再创建表,但是,在 HBase 数据库中,不需要创建数据库,只要直接创建表就可以。在 HBase 中创建 student 表的 Shell 命令如下:

hbase>create 'student', 'Sname', 'Ssex', 'Sage', 'Sdept', 'course'

对于 HBase 而言,在创建 HBasae 表时,不需要自行创建行键,系统会默认一个属性作为行键,通常是把 put 命令操作中跟在表名后的第一个数据作为行键。

创建完 student 表后,可通过 describe 命令查看 student 表的基本信息。describe 命令 及其执行结果如图 5-3 所示。

可以使用 list 命令查看当前 HBase 数据库中已经创建了哪些表,命令如下:

```
hbase(main):009:0> describe 'student'
DESCRIPTION
 'student', {NAME => 'Sage', DATA_BLOCK_ENCODING => 'NONE', BLOOMFILTER => 'NON true
E', REPLICATION_SCOPE => '0', VERSIONS => '3', COMPRESSION => 'NONE', MIN_VERS
IONS => '0', TTL => '2147483647', KEEP_DELETED_CELLS => 'false', BLOCKSIZE =>
 '65536', IN_MEMORY => 'false', ENCODE_ON_DISK => 'true', BLOCKCACHE => 'true'}
 , {NAME => 'Sdept', DATA_BLOCK_ENCODING => 'NONE', BLOOMFILTER => 'NONE', REPL
 ICATION_SCOPE => '0', VERSIONS => '3', COMPRESSION => 'NONE', MIN_VERSIONS =>
 '0', TTL => '2147483647', KEEP_DELETED_CELLS => 'false', BLOCKSIZE => '65536',
 IN_MEMORY => 'false', ENCODE_ON_DISK => 'true', BLOCKCACHE => 'true'}, {NAME
=> 'Sname', DATA_BLOCK_ENCODING => 'NONE', BLOOMFILTER => 'NONE', REPLICATION_
 SCOPE => '0', VERSIONS => '3', COMPRESSION => 'NONE', MIN_VERSIONS => '0', TTL
 => '2147483647', KEEP_DELETED_CELLS => 'false', BLOCKSIZE => '65536', IN_MEMO
RY => 'false', ENCODE_ON_DISK => 'true', BLOCKCACHE => 'true'}, {NAME => 'Ssex
 ', DATA_BLOCK_ENCODING => 'NONE', BLOOMFILTER => 'NONE', REPLICATION_SCOPE =>
 '0', VERSIONS => '3', COMPRESSION => 'NONE', MIN_VERSIONS => '0', TTL => '2147
483647', KEEP_DELETED_CELLS => 'false', BLOCKSIZE => '65536', IN_MEMORY => 'fa
lse', ENCODE_ON_DISK => 'true', BLOCKCACHE => 'true'}, {NAME => 'course', DATA
 _BLOCK_ENCODING => 'NONE', BLOOMFILTER => 'NONE', REPLICATION_SCOPE => '0', VE
RSIONS => '3', COMPRESSION => 'NONE', MIN_VERSIONS => '0', TTL => '2147483647'
, KEEP_DELETED_CELLS => 'false', BLOCKSIZE => '65536', IN_MEMORY => 'false', E
NCODE_ON_DISK => 'true', BLOCKCACHE => 'true'}
 row(s) in 0.0380 seconds
```

图 5-3 describe 命令执行结果

#### 5.3.2 添加数据

HBase 使用 put 命令添加数据,一次只能为一个表的一行数据的一个列(也就是一个单元格,单元格是 HBase 中的概念)添加一个数据,所以,直接用 Shell 命令插入数据效率很低,在实际应用中,一般都是利用编程操作数据。因为这里只要插入一条学生记录,所以,可以用 Shell 命令手工插入数据,命令如下:

```
hbase>put 'student','95001','Sname','LiYing'
```

上面的 put 命令会为 student 表添加学号为'95001'、名字为'LiYing'的一个单元格数据, 其行键为 95001,也就是说,系统默认把跟在表名 student 后面的第一个数据作为行键。

下面继续添加 4 个单元格的数据,用来记录 LiYing 同学的相关信息,命令如下:

```
hbase>put 'student','95001','Ssex','male'
hbase>put 'student','95001','Sage','22'
hbase>put 'student','95001','Sdept','CS'
hbase>put 'student','95001','course:math','80'
```

#### 5.3.3 查看数据

HBase 中有两个用于查看数据的命令。

- (1) get 命令:用于查看表的某一个单元格数据。
- (2) scan 命令:用于查看某个表的全部数据。

例如,可以使用如下命令返回 student 表中 95001 行的数据:

上述命令的执行结果如图 5-4 所示。

图 5-4 get 命令的执行结果

下面使用 scan 命令查询 student 表的全部数据:

```
hbase>scan 'student'
```

上面 scan 命令的执行结果如图 5-5 所示。

图 5-5 scan 命令的执行结果

#### 5.3.4 删除数据

在 HBase 中用 delete 以及 deleteall 命令进行删除数据操作,两者的区别是: delete 命令用于删除一个单元格数据,是 put 的反向操作;而 deleteall 命令用于删除一行数据。

首先使用 delete 命令删除 student 表中 95001 这行中的 Ssex 列的所有数据,命令如下:

```
hbase>delete 'student','95001','Ssex'
```

上面的 delete 命令的执行结果如图 5-6 所示。

图 5-6 delete 命令的执行结果

从中可以看出,95001 这行中的 Ssex 列的所有数据已经被删除。

然后使用 deleteall 命令删除 student 表中的 95001 行的全部数据,命令如下:

hbase>deleteall 'student', '95001'

#### 5.3.5 删除表

删除表需要分两步操作:第一步先让该表不可用;第二步删除表。例如,要删除 student 表,可以使用如下命令:

```
hbase>disable 'student'
hbase>drop 'student'
```

## 5.3.6 查询历史数据

在添加数据时,HBase会自动为添加的数据添加一个时间戳。在修改数据时,HBase会为修改后的数据生成一个新的版本(时间戳),从而完成"改"操作,旧的版本依旧保留,系统会定时回收垃圾数据,只留下最新的几个版本,保存的版本数可以在创建表的时候指定。

为了查询历史数据,这里创建一个 teacher 表,在创建表的时候,需要指定保存的版本数(假设指定为 5),命令如下:

```
hbase>create 'teacher', {NAME=> 'username', VERSIONS=>5}
```

然后插入数据,并更新数据,使其产生历史版本数据,需要注意的是,这里插入数据和更新数据都是使用 put 命令,具体如下:

```
hbase>put 'teacher','91001','username','Mary'
hbase>put 'teacher','91001','username','Mary1'
hbase>put 'teacher','91001','username','Mary2'
hbase>put 'teacher','91001','username','Mary3'
hbase>put 'teacher','91001','username','Mary4'
hbase>put 'teacher','91001','username','Mary5'
```

查询时默认情况下会显示当前最新版本的数据,如果要查询历史数据,需要指定查询的历史版本数,由于上面设置了保存版本数为5,所以,在查询时指定的历史版本数的有效取值为1到5,具体命令如下:

```
hbase>get 'teacher','91001',{COLUMN=>'username',VERSIONS=>5}
hbase>get 'teacher','91001',{COLUMN=>'username',VERSIONS=>3}
```

上述命令执行后的结果如图 5-7 所示。

## 5.3.7 退出 HBase 数据库

最后退出数据库操作,输入 exit 命令即可退出,命令如下:

```
hbase(main):020:0>
                     get 'teacher','91001',{COLUMN=>'username',VERSIONS=>5}
COLUMN
                      CELL
username:
                      timestamp=1469451374420, value=Mary5
                      timestamp=1469451369561, value=Mary4
username:
                      timestamp=1469451366448, value=Mary3
username:
                      timestamp=1469451363530, value=Mary2
username:
                      timestamp=1469451351102, value=Mary1
username:
5 row(s) in 0.0290 seconds
                     get 'teacher','91001',{COLUMN=>'username',VERSIONS=>3}
hbase(main):021:0>
COLUMN
username:
                      timestamp=1469451374420, value=Mary5
username:
                      timestamp=1469451369561, value=Mary4
username:
                      timestamp=1469451366448, value=Mary3
3 row(s) in 0.0310 seconds
hbase(main):022:0>
```

图 5-7 get 命令的执行结果

```
hbase>exit
```

**注意**: 这里退出 HBase 数据库是退出 HBase Shell,而不是停止 HBase 数据库后台运行,执行 exit 后,HBase 仍然在后台运行,如果要停止 HBase 运行,需要使用如下命令:

```
$bin/stop-hbase.sh
```

# 5.4 HBase 编程实践

HBase 提供了 Java API 对 HBase 数据库进行操作。本书采用 Eclipse 进行程序开发,第 4 章已经详细介绍了 Eclipse 软件的安装方法,这里不再赘述。在进行 HBase 编程之前,如果还没有启动 Hadoop 和 HBase,需要首先启动 Hadoop 和 HBase,但是,不需要启动 HBase Shell,具体命令如下:

```
$cd /usr/local/hadoop
$./sbin/start-dfs.sh
$cd /usr/local/hbase
$./bin/start-hbase.sh
```

# 5.4.1 在 Eclipse 中创建项目

Eclipse 启动以后,会弹出如图 5-8 所示的界面,提示设置工作空间(workspace)。

可以直接采用默认的设置/home/hadoop/workspace,单击 OK 按钮。可以看出,由于当前是采用 hadoop 用户登录了 Linux 系统,因此,默认的工作空间目录位于 hadoop 用户目录/home/hadoop下。

Eclipse 启动以后,呈现的界面如图 5-9 所示。

可以看到, Eclipse 里已经存在一个名称为 HDFSExample 的工程,这是介绍第 4 章时 创建的 Java 工程。为了减少不必要的干扰,这里可以删除这个工程,如图 5-10 所示,在工

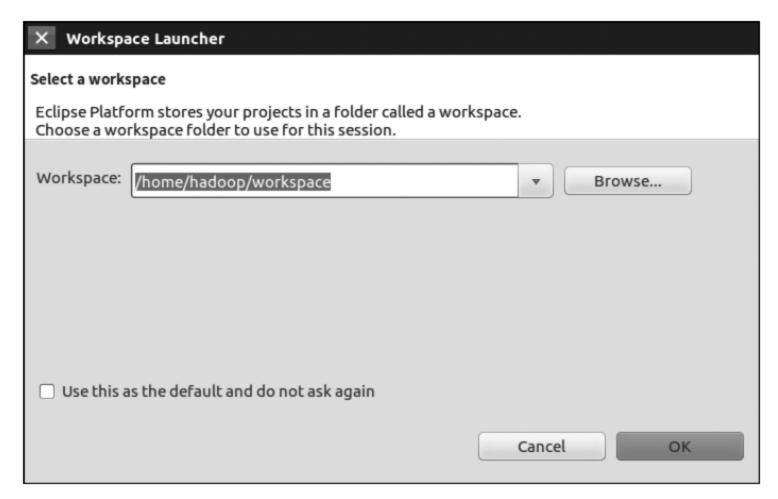


图 5-8 Eclipse 启动以后的工作空间设置界面

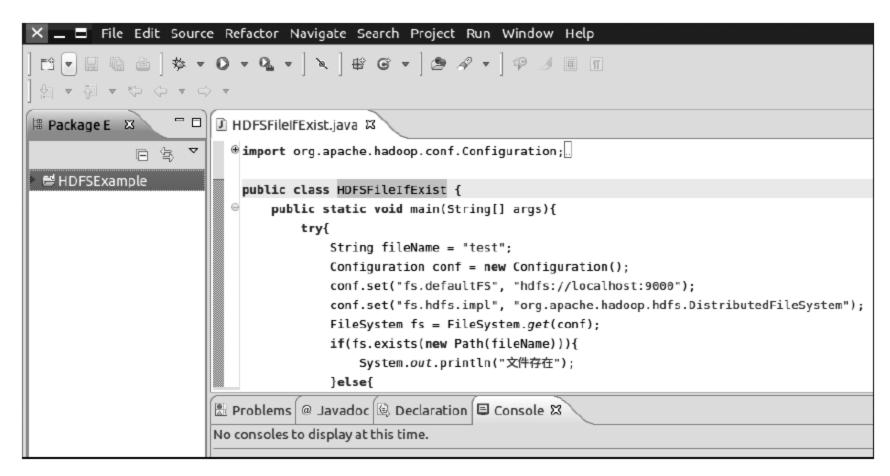


图 5-9 Eclipse 启动进入以后的界面

程名称 HDFSExample 上右击,在弹出的快捷菜单中选择 Delete。

单击 Delete 选项以后,会弹出如图 5-11 所示的界面。

在这个界面中,如果选中 Delete project contents on disk(cannot be undone)复选框,则会删除整个 HDFSExample 工程及其代码。如果没有选中这个选项,则工程代码依旧保存在磁盘上,以后可以继续加载到 Eclipse 中。这里不选中这个选项,然后单击 OK 按钮,删除 HDFSExample 工程。

然后选择 File→New→Java Project 命令,开始创建一个 Java 工程,弹出如图 5-12 所示的界面。

在 Project name 后面的文本框中输入工程名称 HBaseExample, 选中 Use default location

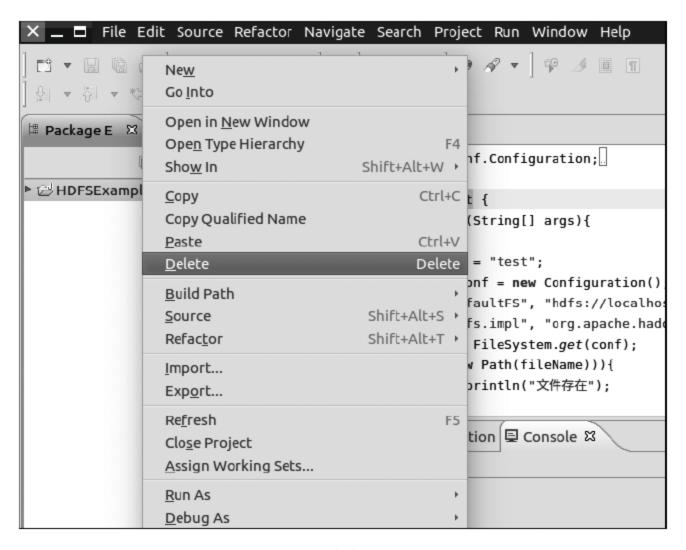


图 5-10 删除 Java 工程

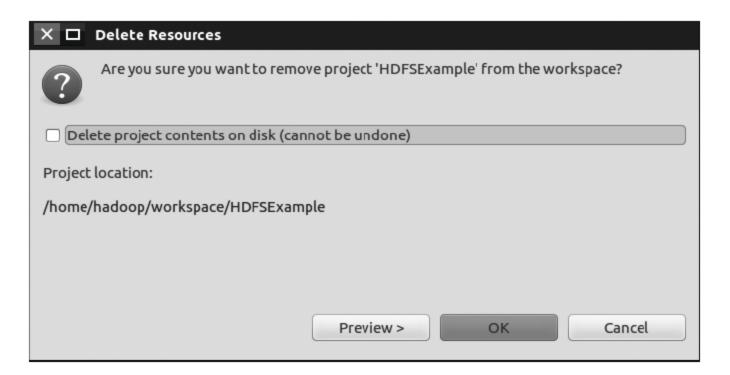


图 5-11 删除 Java 工程时的提示信息

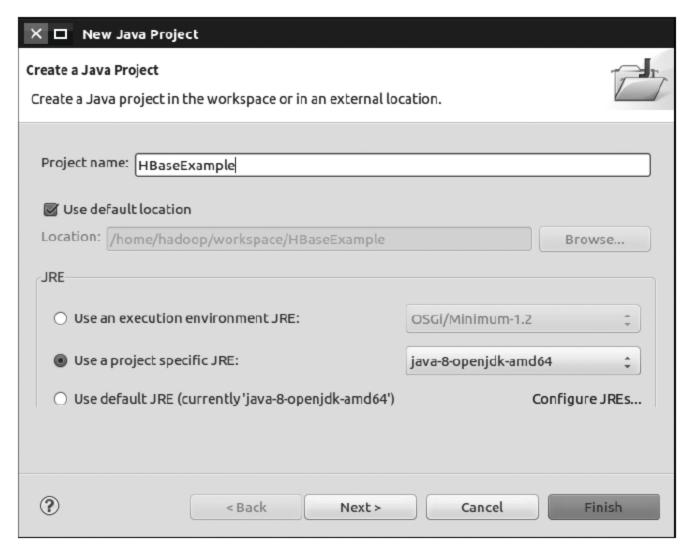


图 5-12 为 HBase 应用程序新建一个 Java 工程

复选框,让 Java 工程的所有文件都保存到/home/hadoop/workspace/HBaseExample 目录下。在 JRE 选项卡中,可以选择当前的 Linux 系统中已经安装好的 JDK,如 java-8-openjdk-amd64。然后单击界面底部的 Next 按钮,进入下一步设置。

# 5.4.2 为项目添加需要用到的 JAR 包

进入下一步的设置以后,会弹出如图 5-13 所示的界面。

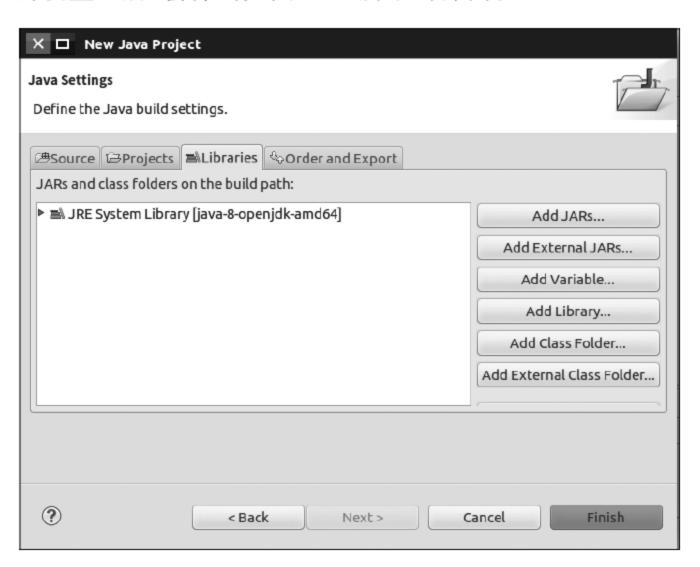


图 5-13 添加 JAR 包界面

为了编写一个能够与 HBase 交互的 Java 应用程序,需要在这个界面中加载该 Java 工程所需要用到的 JAR 包,这些 JAR 包中包含了可以访问 HBase 的 Java API。这些 JAR 包都位于 Linux 系统的 HBase 安装目录的 lib 目录下,也就是位于/usr/local/hbase/lib 目录下。单击界面中的 Libraries 选项卡,然后单击界面右侧的 Add External JARs 按钮,弹出如图 5-14 所示界面。

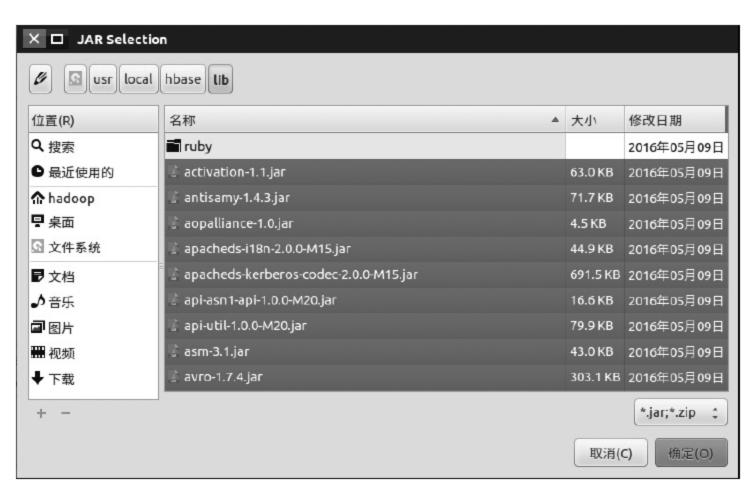


图 5-14 选择需要的 JAR 包

选中/usr/local/hbase/lib 目录下的所有 JAR 包(但是,不要选中 ruby 文件夹),然后单 击界面右下角的"确定"按钮。

添加完毕以后,就可以单击界面右下角的 Finish 按钮,完成 Java 工程 HBaseExample 的创建。

#### 5.4.3 编写 Java 应用程序

下面编写一个 Java 应用程序,对 HBase 数据库进行操作。

在 Eclipse 工作界面左侧的 Package Explorer 面板中(见图 5-15)找到刚才创建好的工程名称 HBaseExample,然后在该工程名称上右击,在弹出的菜单中选择 New→Class 命令。

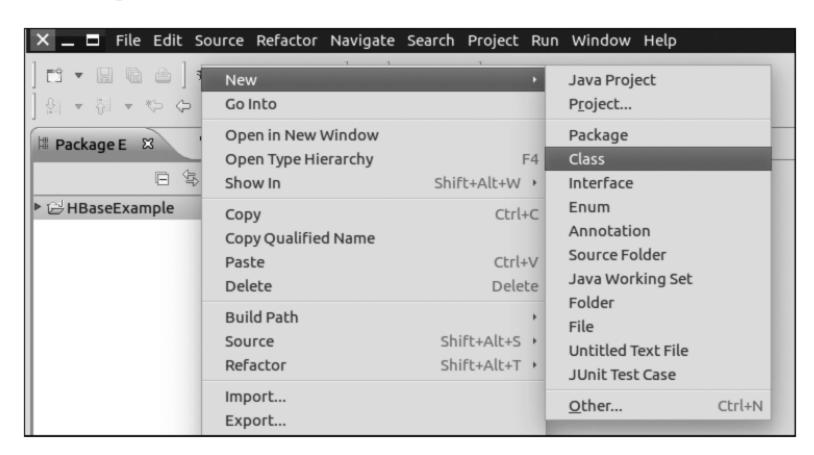


图 5-15 新建 Java Class 文件

选择 New→Class 命令以后会出现如图 5-16 所示的界面。

X □ New Java Class						
Java Class  The use of the def	ault package is discouraged.					
Source folder:	HBaseExample/src	Browse				
Package:	(default)	Browse				
☐ Enclosing type:		Browse				
Name: Modifiers:	HBaseOperation  public default private protected abstract final static					
Superclass:	java.lang.Object	Browse				
Interfaces:		Add				
?	Cancel	Finish				

图 5-16 新建 Java Class 文件时的设置界面

在该界面中只需要在 Name 后面的文本框中输入新建的 Java 类文件的名称,这里采用 名称 HBaseOperation,其他都可以采用默认设置;然后单击界面右下角的 Finish 按钮,出现 如图 5-17 所示的界面。

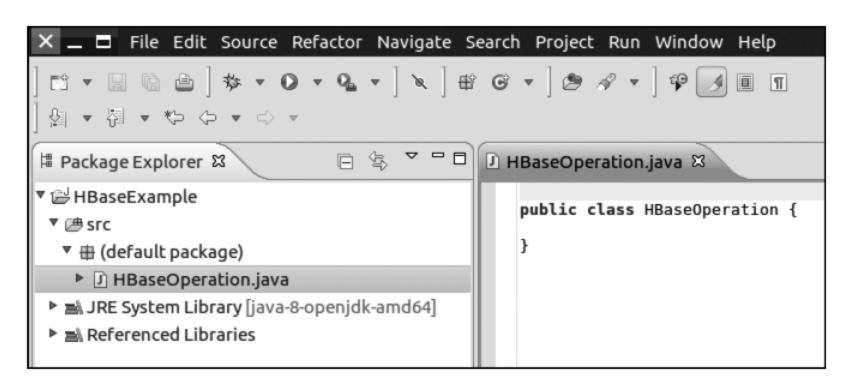


图 5-17 新建一个类文件以后的 Eclipse 界面

可以看出, Eclipse 自动创建了一个名为 HBaseOperation. java 的源代码文件, 在该文件中输入以下代码:

```
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.hbase.*;
import org.apache.hadoop.hbase.client.*;
import java.io.IOException;
public class HBaseOperation{
    public static Configuration configuration;
    public static Connection connection;
    public static Admin admin;
    public static void main(String[] args)throws IOException{
        createTable("t2",new String[]{"cf1","cf2"});
        insertRow("t2", "rw1", "cf1", "q1", "val1");
        getData("t2", "rw1", "cf1", "q1");
        //deleteTable("t2"); //如果不想执行本行代码,可以注释掉本行代码
    //建立连接
    public static void init() {
        configuration=HBaseConfiguration.create();
        configuration.set("hbase.rootdir", "hdfs://localhost:9000/hbase");
        try{
            connection=ConnectionFactory.createConnection(configuration);
            admin=connection.getAdmin();
        }catch (IOException e) {
            e.printStackTrace();
```

```
//关闭连接
public static void close(){
    try{
        if(admin !=null){
             admin.close();
        }
        if(null !=connection) {
            connection.close();
        }
    }catch (IOException e) {
        e.printStackTrace();
//建立表
public static void createTable(String myTableName,String[] colFamily)
throws IOException {
    init();
    TableName tableName=TableName.valueOf(myTableName);
    if (admin.tableExists(tableName)) {
        System.out.println("talbe is exists!");
    }else {
        HTableDescriptor hTableDescriptor=new HTableDescriptor (tableName);
        for (String str:colFamily) {
            HColumnDescriptor hColumnDescriptor new HColumnDescriptor (str);
            hTableDescriptor.addFamily(hColumnDescriptor);
        }
        admin.createTable(hTableDescriptor);
    close();
//删除表
public static void deleteTable (String tableName) throws IOException {
    init();
    TableName tn=TableName.valueOf(tableName);
    if (admin.tableExists(tn)) {
        admin.disableTable(tn);
        admin.deleteTable(tn);
    }
    close();
//查看已有表
public static void listTables() throws IOException {
```

```
init();
    HTableDescriptor hTableDescriptors[]=admin.listTables();
    for (HTableDescriptor hTableDescriptor: hTableDescriptors) {
        System.out.println(hTableDescriptor.getNameAsString());
    close();
public static void insertRow (String tableName, String rowKey, String
colFamily, String col, String val) throws IOException {
    init();
    Table table=connection.getTable(TableName.valueOf(tableName));
    Put put=new Put (rowKey.getBytes());
    put.addColumn(colFamily.getBytes(), col.getBytes(), val.getBytes());
    table.put(put);
    table.close();
    close();
//删除数据
public static void deleteRow (String tableName, String rowKey, String
colFamily, String col) throws IOException {
    init();
    Table table=connection.getTable(TableName.valueOf(tableName));
    Delete delete= new Delete (rowKey.getBytes());
    //删除指定列族
    //delete.addFamily(Bytes.toBytes(colFamily));
    //删除指定列
    //delete.addColumn (Bytes.toBytes (colFamily), Bytes.toBytes (col));
    table.delete(delete);
    table.close();
    close();
//根据 rowkey 查找数据
public static void getData (String tableName, String rowKey, String
colFamily, String col) throws IOException{
    init();
    Table table=connection.getTable(TableName.valueOf(tableName));
    Get get=new Get(rowKey.getBytes());
    get.addColumn(colFamily.getBytes(),col.getBytes());
    Result result=table.get(get);
    showCell(result);
    table.close();
    close();
```

上述代码可以从本书官网的"下载专区"中下载,单击进入下载专区后,在"代码"这个文件夹中,找到第5章文件夹下的 HBaseOperation. java 文件下载到本地。在上述代码中,用来删除表的语句 deleteTable("t2")被注释掉了,如果要使用该行代码,可以把注释去掉,但是,为了顺利演示下面内容,请暂时注释掉该行代码。

上述代码输入到 HBaseOperation. java 中以后, Eclipse 可能会显示一些错误信息,如图 5-18 所示。

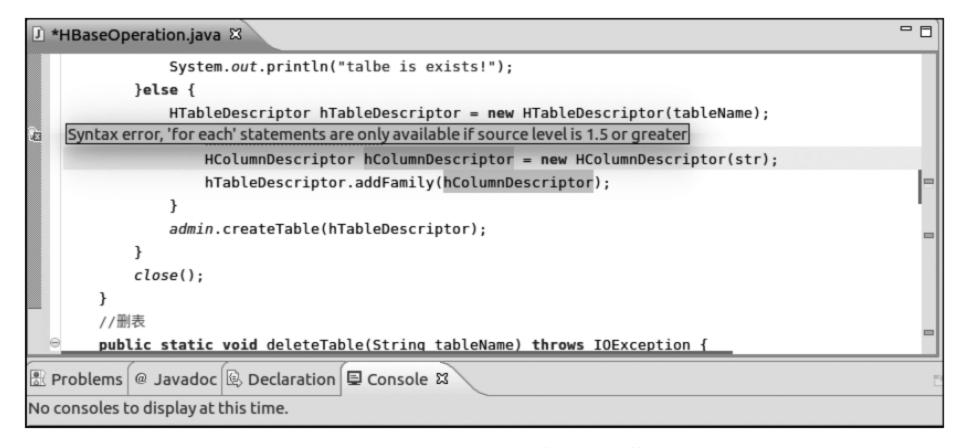


图 5-18 Eclipse 提示的代码错误信息

可以看出,图 5-18 中显示的错误如下:

```
Syntax error, 'for each' statements are only available if source level is 1.5 or greater
```

之所以出现这个错误,是因为 HBaseOperation. java 代码中的一些语句的语法(如 for (String str:colFamily)),是在 JDK 1.5 以上版本才支持的,JDK 1.4 以及之前的版本不支

持这些语法。

现在可以查看一下 Linux 系统中安装的 Eclipse 的相关设置,如图 5-19 所示,在顶部菜单中选择 Project,在弹出的子菜单中选择 Properties。

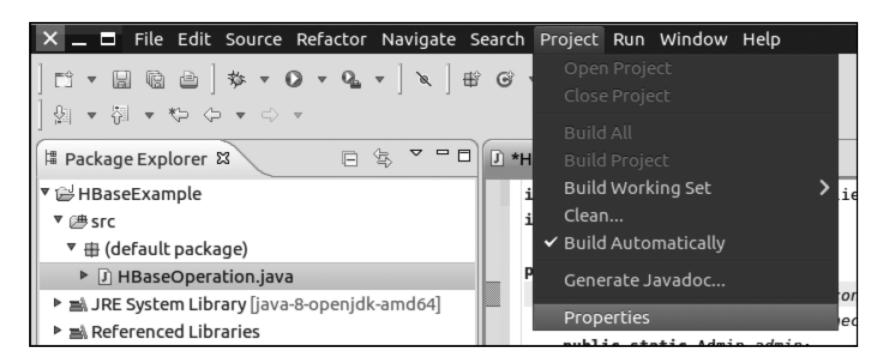


图 5-19 Eclipse 菜单

然后会弹出如图 5-20 所示的界面。

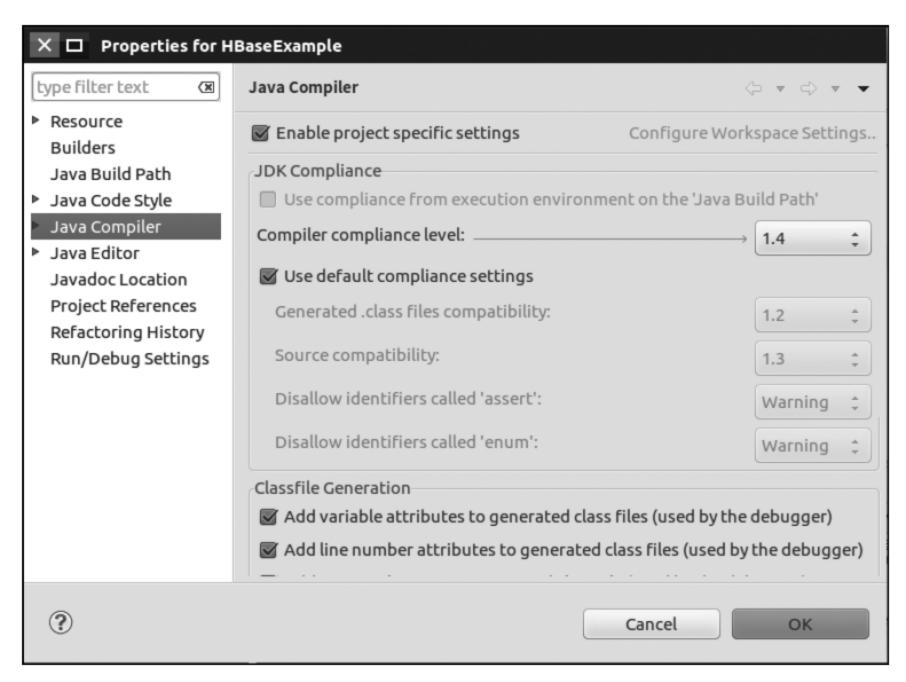


图 5-20 属性设置界面

在该界面中单击左侧栏目的 Java Compiler,在右边出现的信息中可以看出,Compiler compliance level 当前默认的设置为 1.4,不支持 HBaseOperation. java 代码中的一些语句的语法(如 for(String str:colFamily))。

为了解决这个错误,如图 5-21 所示,单击错误提示图标,在弹出的对话框中,在 Change project compliance and JRE to 1.5 这行文字上双击,就可以让错误信息消失。

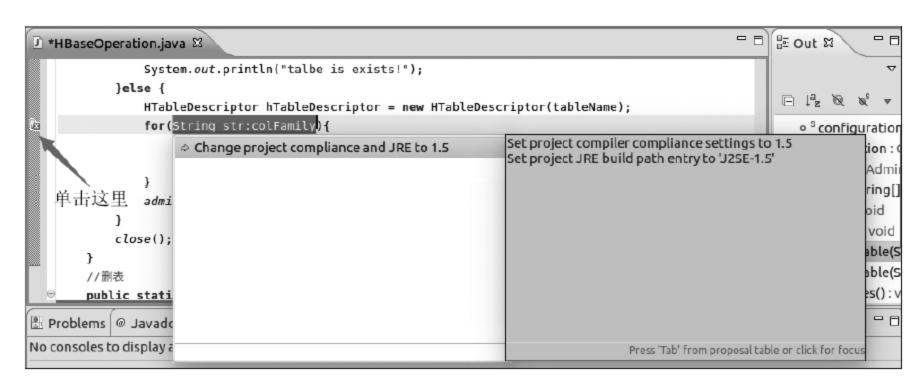


图 5-21 错误解决方法

# 5.4.4 编译运行程序

再次强调,在开始编译运行程序之前,一定要确保 Hadoop 和 HBase 已经启动运行。现在就可以编译运行上面编写的代码。可以直接单击 Eclipse 工作界面上部的运行程序的快捷按钮,当把鼠标移动到该按钮上时,在弹出的菜单中选择 Run as→Java Application 命令,如图 5-22 所示。

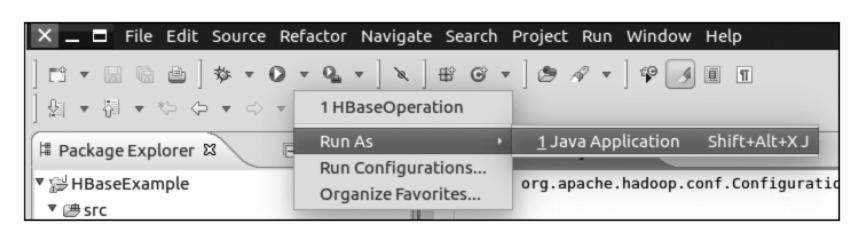


图 5-22 运行程序

程序运行结束后,结果如图 5-23 所示, Console 面板中还会显示一些类似"log4j: WARN···"的警告信息,可以不用理会。

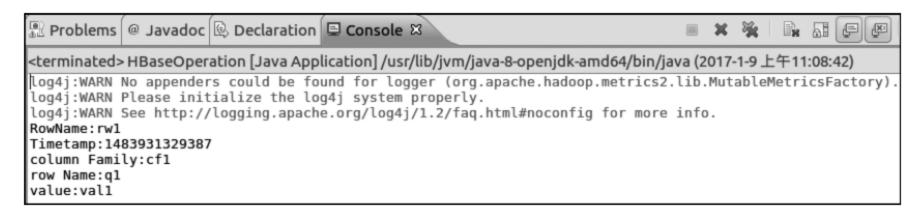


图 5-23 控制台中输出的程序运行结果信息

现在可以在 Linux 的终端中启动 HBase Shell,来查看生成的 t1 表,启动 HBase Shell 的命令如下:

\$cd /usr/local/hbase
\$./bin/hbase shell

进入 HBase Shell 以后,可以使用 list 命令查看 HBase 数据库中是否存在名称为 t1 的表。

hbase>list

然后可以使用 get 命令查询刚才插入到 t2 中的一行数据:

hbase>get 't2','rw1'

最后如果要重复调试 HBaseOperation. java 代码,则需要删除 HBase 中已经创建的表t2,可以使用 Shell 命令删除 t2,命令如下:

hbase>disable 't2'
hbase>drop 't2'

## 5.4.5 应用程序的部署

可以把上面编写的 Java 应用程序打包后部署到 Hadoop 平台上运行。具体部署方法和第 4 章中介绍的应用程序部署方法一样,这里不再赘述。

# 5.5 本章小结

HBase 属于列族数据库,是 NoSQL 数据库的一种,它是 Hadoop 生态系统中的重要一员,借助于 Hadoop 的力量,HBase 获得很好的发展空间,得到了大量的应用。

本章首先介绍 HBase 的安装方法,包括下载安装文件、配置环境变量和添加用户权限等;然后详细介绍 HBase 的两种不同模式的配置方法,包括单机模式的配置和伪分布式模式的配置。在实际应用中,需要经常使用 Shell 命令操作 HBase 数据库,因此,本章详细介绍了一些常用的 HBase Shell 命令的使用方法,包括创建表、添加数据、查看数据、删除数据等;最后本章详细介绍 HBase 的 Java 应用程序开发方法。

# 第6章

# 典型 NoSQL 数据库的安装和使用

NoSQL数据库是一大类非关系型数据库的统称,较好地满足了大数据时代不同类型数据的存储需求,开始得到越来越广泛的应用。NoSQL数据库主要包括键值数据库、列族数据库、文档数据库和图数据库4种类型,不同产品都有各自的应用场合。

本章重点介绍键值数据库 Redis 和文档数据库 MongoDB 的安装和使用方法,并给出简单的编程实例。

# 6.1 Redis 安装和使用

本节内容包括 Redis 简介、安装 Redis 和 Redis 实例演示等。

# 6.1.1 Redis 简介

Redis 是一个键值(key-value)存储系统,即键值对非关系型数据库,和 Memcached 类似,目前正在被越来越多的互联网公司采用。Redis 作为一个高性能的键值数据库,不仅在很大程度上弥补了 memcached 这类键值存储的不足,而且在部分场合下可以对关系数据库起到很好的补充作用。Redis 提供了 Python、Ruby、Erlang、PHP 客户端,使用很方便。

Redis 支持存储的值(value)类型包括 string(字符串)、list(链表)、set(集合)和 zset(有序集合)。这些数据类型都支持 push/pop、add/remove 以及取交集、并集和差集等丰富的操作,而且这些操作都是原子性的。在此基础上,Redis 支持各种不同方式的排序。与memcached一样,为了保证效率,Redis中的数据都是缓存在内存中的,它会周期性地把更新的数据写入磁盘,或者把修改操作写入追加的记录文件;此外,Redis 还实现了主从(master-slave)同步。

#### 6.1.2 安装 Redis

首先登录 Linux 系统(本书全部统一使用 hadoop 用户登录),打开浏览器,访问 Redis 官网(https://redis.io/)下载安装包 redis-3.2.7. tar. gz,或者访问本书官网的"下载专区",到"软件"目录下把 redis-3.2.7. tar. gz 文件下载到本地。下载后的 redis-3.2.7. tar. gz 文件,保存在/home/hadoop/下载目录下。然后,打开一个终端,执行以下命令将 Redis 解压至/usr/local/目录下并重命名:

\$cd ~
\$sudo tar - zxvf ./下载/redis-3.2.7.tar.gz - C /usr/local
\$cd /usr/local

\$sudo mv ./redis-3.2.7 ./redis

然后执行如下命令把 redis 目录的权限赋予 hadoop 用户:

\$sudo chown -R hadoop:hadoop ./redis

接下来进入/usr/local/redis 目录,输入以下命令编译和安装 Redis:

\$sudo make \$sudo make install

至此, Redis 已经安装完成, 现在可以执行如下命令开启 Redis 服务器:

\$cd /usr/local/redis
\$./src/redis-server

如果有如图 6-1 所示的输出,则表示安装成功。



图 6-1 Redis 服务器启动后的屏幕信息

然后再新建一个终端,输入如下命令启动 Redis 客户端:

\$cd /usr/local/redis
\$./src/redis-cli

如图 6-2 所示,客户端连上服务器之后,会显示"127.0.0.1:6379>"的命令提示符信

息,表示服务器的 IP 地址为 127.0.0.1,端口号为 6379。现在可以执行简单的操作,例如,设置键为"hello",值为"world",并且取出键为"hello"时对应的值,图 6-2 给出了具体的操作效果。

```
charles@charles-Aspire-4741:~/redis-3.2.7$ ./src/redis-cli
127.0.0.1:6379> set hello world
OK
127.0.0.1:6379> get hello
"world"
127.0.0.1:6379>
```

图 6-2 客户端连接上服务器后的简单操作

至此, Redis 安装和运行成功, 接下来, 即可操作 Redis 数据库。

#### 6.1.3 Redis 实例演示

假设有 3 个表,即 Student、Course 和 SC,3 个表的字段(列)和数据如图 6-3 所示。

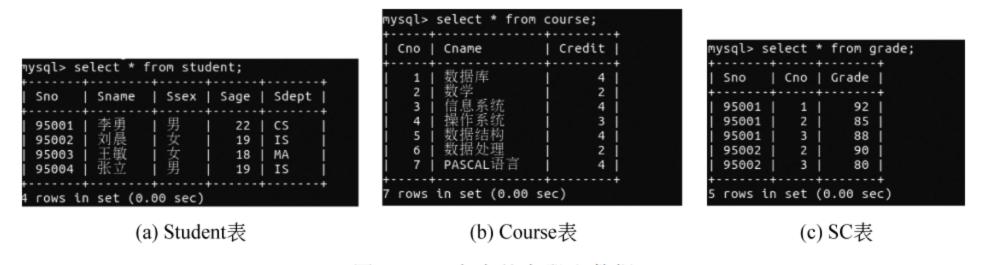


图 6-3 3 个表的字段和数据

Redis 数据库是以<key,value>的形式存储数据,把 3 个表的数据存入 Redis 数据库时,key 和 value 的确定方法如下:

```
key=表名:主键值:列名 value=列值
```

例如,把每个表的第一行记录保存到 Redis 数据中,需要执行的命令和执行结果如图 6-4 所示。

```
charles@charles-Aspire-4741:~/redis-3.2.7$ ./src/redis-cli
127.0.0.1:6379> set Student:95001:Sname 李勇
OK
127.0.0.1:6379> set Course:1:Cname 数据库
OK
127.0.0.1:6379> set SC:95001:1:Grade 92
OK
127.0.0.1:6379>
```

图 6-4 向 Redis 中插入数据

可以执行类似的命令,把3个表中的所有数据都插入到Redis数据库中。然后针对这些已经录入的数据,下面将简单演示如何进行增、删、改、查操作。Redis支持5种数据类型,不同数据类型,增、删、改、查可能不同,这里用最简单的数据类型字符串作为演示。

#### 1. 插入数据

向 Redis 插入一条数据,只需要先设计好 key 和 value,然后用 set 命令插入数据即可。

例如,在 Course 表中插入一门新的课程"算法",4 学分,操作命令和结果如图 6-5 所示。

```
127.0.0.1:6379> set Course:8:Cname 算法
OK
127.0.0.1:6379> set Course:8:Ccredit 4
OK
127.0.0.1:6379>
```

图 6-5 插入数据

#### 2. 修改数据

Redis 并没有修改数据的命令,所以,如果在 Redis 中修改一条数据,只能采用一种变通的方式,即在使用 set 命令时,使用同样的 key,然后用新的 value 值来覆盖旧的数据。例如,把刚才新添加的"算法"课程名称修改为"编译原理",操作命令和结果如图 6-6 所示。

```
127.0.0.1:6379> get Course:8:Cname
算法
127.0.0.1:6379> set Course:8:Cname 编译原理
OK
127.0.0.1:6379> get Course:8:Cname
编译原理
127.0.0.1:6379>
```

图 6-6 修改数据

#### 3. 删除数据

Redis 有专门删除数据的命令——del 命令,命令格式为"del 键"。所以,如果要删除之前新增的课程"编译原理",只需输入命令"del Course:8:Cname",如图 6-7 所示。当输入 "del Course:8:Cname"时,返回 1,说明成功删除一条数据;当再次输入 get 命令时,输出为空,说明删除成功。

```
127.0.0.1:6379> get Course:8:Cname
编译原理
127.0.0.1:6379> del Course:8:Cname
1
127.0.0.1:6379> get Course:8:Cname
```

图 6-7 删除数据

#### 4. 查询数据

Redis 最简单的查询方式是使用 get 命令,上面几个操作中都已经使用过 get 命令,这里不再赘述。

# 6.2 MongoDB的安装和使用

本节介绍 MongoDB 的安装和使用方法,包括安装 Mongo、使用 Shell 命令操作 MongoDB 以及 Java API 编程实例等。

#### 6.2.1 MongDB 简介

MongoDB是一个基于分布式文件存储的文档数据库,介于关系数据库和非关系数据库之间,是非关系数据库当中功能最丰富、最像关系数据库的一种 NoSQL 数据库。MongoDB 支持的数据结构非常松散,是类似 json 的 bson 格式,因此可以存储比较复杂的数据类型。Mongo 最大的特点是支持的查询语言非常强大,语法有点类似于面向对象的查询语言,几乎可以实现类似关系数据库单表查询的绝大部分功能,而且还支持对数据建立索引。

# 6.2.2 安装 MongoDB

MongoDB 既可以安装在 Windows 系统下使用,也可以安装在 Linux 系统下使用,这里 采用 Linux 系统。MongoDB 的安装很简单,无须下载源文件,可以直接用 apt-get 命令进行 安装。

但是,需要说明的是,如果直接使用 sudo apt-get install mongodb 命令进行安装,默认安装的版本是 MongoDB 2. 6. 10。由于目前 MongoDB 已经升级到 3. 2. 8,这里将通过添加软件源的方式来安装 3. 2. 8 版本。

首先在 Linux 系统中打开一个终端,执行如下命令导入公共密钥到包管理器中:

\$sudo apt-key adv -- keyserver hkp://keyserver.ubuntu.com:80 -- recv EA312927

然后创建 MongoDB 的文件列表,命令如下:

\$echo "deb http://repo.mongodb.org/apt/ubuntu trusty/mongodb-org/3.2
multiverse" | sudo tee /etc/apt/sources.list.d/mongodb-org-3.2.list

执行如下命令来更新包管理器:

\$sudo apt-get update

最后执行如下命令安装 MongoDB:

\$sudo apt-get install -y mongodb-org

安装完成后,在终端输入以下命令查看 MongoDB 版本:

\$mongo - version

如果能够输出版本信息(见图 6-8),则表明安装成功。

dblab@ubuntu:~\$ mongo -version MongoDB shell version: 3.2.8 dblab@ubuntu:~\$ 安装成功以后,启动 MongoDB 的命令如下:

```
$sudo service mongodb start
```

默认设置下, Mongo DB 是随 Ubuntu 启动而自动启动的。可以输入以下命令查看是否启动成功:

```
$pgrep mongo - 1 #注意: - 1 是英文字母 1, 不是阿拉伯数字 1
```

如果能够出现如图 6-9 所示的信息,则表明启动成功。

```
dblab@ubuntu:~$ pgrep mongo -l
3498 mongod
dblab@ubuntu:~$
```

图 6-9 查询 MongoDB 是否启动成功

使用 MongoDB 结束后,关闭 MongoDB 的命令如下:

```
$sudo service mongodb stop
```

## 6.2.3 使用 Shell 命令操作 MongoDB

### 1. 进入 MongoDB Shell 模式

在 Linux 系统打开一个终端,输入如下命令启动 MongoDB:

```
$sudo service mongodb start
```

再输入如下命令进入 MongoDB Shell 模式:

```
$mongo
```

执行该命令后,屏幕截图如图 6-10 所示。

```
dblab@ubuntu:/usr/local/mongodb$ mongo
MongoDB shell version: 3.2.8
connecting to: test
Server has startup warnings:
2017-02-13T11:12:24.614+0800 I CONTROL [initandlisten]
2017-02-13T11:12:24.614+0800 I CONTROL [initandlisten] ** WARNING: /sys/kernel
/mm/transparent_hugepage/enabled is 'always'.
2017-02-13T11:12:24.614+0800 I CONTROL [initandlisten] **
                                                                  We suggest se
tting it to 'never'
2017-02-13T11:12:24.614+0800 I CONTROL [initandlisten]
2017-02-13T11:12:24.614+0800 I CONTROL [initandlisten] ** WARNING: /sys/kernel
/mm/transparent_hugepage/defrag is 'always'.
2017-02-13T11:12:24.614+0800 I CONTROL [initandlisten] **
                                                                  We suggest se
tting it to 'never'
2017-02-13T11:12:24.614+0800 I CONTROL [initandlisten]
```

图 6-10 MongoDB Shell 模式

进入 MongoDB Shell 模式以后,默认连接的数据库是 test 数据库,可以在命令提示符 ">"后面输入各种 Shell 命令来操作 MongoDB 数据库。

### 2. 常用操作命令

常用的操作 MongoDB 数据库的相关命令包括如下。

- (1) show dbs:显示数据库列表。
- (2) show collections:显示当前数据库中的集合(类似于关系数据库中的表 table)。
- (3) show users:显示所有用户。
- (4) use yourDB: 切换当前数据库至 yourDB。
- (5) db. help():显示数据库操作命令。
- (6) db. yourCollection. help():显示集合操作命令,yourCollection是集合名。

MongoDB 没有创建数据库的命令,如果要创建一个名称为 School 的数据库,需要先运行 use School 命令,之后做一些操作,例如,使用命令 db. createCollection('teacher')创建集合,这样就可以创建一个名称为 School 的数据库,执行上述命令过程的屏幕截图如图 6-11 所示。

```
> show dbs
admin 0.078GB
local 0.078GB
test 0.078GB
> use School
switched to db School
> db.createCollection('teacher')
{ "ok" : 1 }
> show dbs
School 0.078GB
admin 0.078GB
local 0.078GB
test 0.078GB
```

图 6-11 创建数据库和集合

## 3. 简单操作演示

下面以一个 School 数据库为例进行操作演示,将在 School 数据库中创建两个集合 teacher 和 student,并对 student 集合中的数据进行增、删、改、查等基本操作。需要说明的是,文档数据库中的集合(Collection)相当于关系型数据库中的表(table)。

1) 切换到 School 数据库 命令如下:

>use School

注意: MongoDB 无须预创建 School 数据库,在使用时会自动创建。

2) 创建集合

创建集合(Collection)的命令如下:

```
>db.createCollection('teacher')
```

执行上述命令的屏幕截图如图 6-12 所示。

```
> show collections
system.indexes
> db.createCollection('teacher')
{ "ok" : 1 }
> show collections
system.indexes
teacher
>
```

图 6-12 创建集合

实际上, MongoDB 在插入数据的时候, 也会自动创建对应的集合, 无须预定义集合。

#### 3) 插入数据

与数据库创建类似,插入数据时也会自动创建集合。插入数据有两种方式: insert 和 save,具体命令如下:

```
>db.student.insert({_id:1, sname: 'zhangsan', sage: 20}) #_id 可选
>db.student.save({_id:1, sname: 'zhangsan', sage: 22}) #_id 可选
```

这两种方式,其插入的数据中\_id 字段均可不写,系统会自动生成一个唯一的\_id 来标识本条数据。insert 和 save 两者的区别在于: 在手动插入\_id 字段时,如果\_id 已经存在,insert 不做操作,而 save 会做更新操作;如果不加\_id 字段,两者作用相同,都是插入数据。上述命令执行过程的屏幕截图如图 6-13 所示。

```
db.student.insert({_id:1, sname: 'zhangsan', sage: 20})
WriteResult({ "nInserted" : 1 })
  db.student.find()
  "_id" : 1, "sname" : "zhangsan", "sage" : 20 } insert: 插入成功
db.student.save({_id:1, sname: 'zhangsan', sage: 22})
 riteResult({ "nMatched" : 1, "nUpserted" : 0, "nModified" : 1 })
> db.student.find()
  "_id": 1, "sname": "zhangsan", "sage": 22 } save: id相同, 更新数据
 db.student.insert({_id:1, sname: 'zhangsan', sage: 25})
WriteResult({
        "nInserted" : 0,
        "writeError" : {
                 "code" : 11000.
                 "errmsg" : "insertDocument :: caused by :: 11000 E11000 du
plicate key error index: School.student.$ id dup key: { : 1.0 }"
                                                   insert: _id相同,插入失败,
 db.student.find()
                                                   不做操作
    _id" : 1, "sname" : "zhangsan", "sage" : 22 }
```

图 6-13 插入数据

添加的数据的结构是松散的,只要是 bson 格式均可,列属性均不固定,以实际添加的数据为准。可以先定义数据再插入,这样就可以一次性插入多条数据,如图 6-14 所示。

运行完以上例子, student 已自动创建,这也说明 MongoDB 不需要预先定义集合 (collection),在第一次插入数据后,集合会被自动创建。此时,可以使用 show collections 命令查询数据库中当前已经存在的集合,如图 6-15 所示。

```
s = [{sname:'lisi',sage:20},{sname:'wangwu',sage:20},{sname:'chenliu',sage:20}]
                       "sname" : "lisi",
                        "sage" : 20
                        "sname" : "wangwu",
                        "sage" : 20
                       "sname" : "chenliu",
                        "sage" : 20
  db.student.insert(s)
BulkWriteResult({
           "writeErrors" : [ ],
           "writeConcernErrors" : [ ],
            "nInserted" : 3,
           "nUpserted" : 0,
           "nMatched" : 0,
           "nModified" : 0,
           "nRemoved" : 0,
           "upserted" : [ ]
  db.student.find()
  "_id" : 1, "sname" : "zhangsan", "sage" : 22 }

"_id" : ObjectId("577b3a1dacae8736eab65abf"), "sname" : "lisi", "sage" : 20 }

"_id" : ObjectId("577b3a1dacae8736eab65ac0"), "sname" : "wangwu", "sage" : 20 }

"_id" : ObjectId("577b3a1dacae8736eab65ac1"), "sname" : "chenliu", "sage" : 20 }
```

图 6-14 一次性插入多条数据

```
> show collections
student
system.indexes
teacher
>
```

图 6-15 show collections 命令的执行结果

#### 4) 查找数据

查找数据所使用的基本命令格式如下:

```
>db.youCollection.find(criteria, filterDisplay)
```

其中,criteria表示查询条件,是一个可选的参数;filterDisplay表示筛选显示部分数据,如显示指定某些列的数据,这也是一个可选的参数,但是,需要注意的是,当存在该参数时,第一个参数不可省略,若查询条件为空,可用{}作为占位符。

(1) 查询所有记录。

```
>db.student.find()
```

该命令相当于关系数据库的 SQL 语句 select \* from student。

(2) 查询 sname='lisi'的记录。

```
>db.student.find({sname: 'lisi'})
```

该命令相当于关系数据库的 SQL 语句 select \* from student where sname='lisi'。

(3) 查询指定列 sname、sage 数据。

```
>db.student.find({},{sname:1, sage:1})
```

该命令相当于关系数据库的 SQL 语句 select sname, sage from student。其中, sname: 1表示返回 sname 列,默认\_id 字段也是返回的,可以添加\_id:0(意为不返回\_id),写成 {sname: 1, sage: 1,\_id:0},就不会返回默认的\_id 字段了。

(4) AND 条件查询。

```
>db.student.find({sname:'zhangsan', sage: 22})
```

该命令相当于关系数据库的 SQL 语句 select \* from student where sname='zhangsan' and sage=22。

(5) OR 条件查询。

```
>db.student.find({$or: [{sage: 22}, {sage: 25}]})
```

该命令相当于关系数据库的 SQL 语句 select \* from student where sage=22 or sage=25。 (6) 格式化输出。

对于查询结果,也可以采用 pretty()进行格式化输出,命令执行结果如图 6-16 所示。

图 6-16 格式化输出

### 5) 修改数据

修改数据的基本命令格式如下:

```
>db.youCollection.update(criteria, objNew, upsert, multi)
```

对于该命令做如下说明。

- (1) criteria:表示 update 的查询条件,类似 sql update 查询内 where 后面的条件。
- (2) objNew: update 的对象和一些更新的操作符(如\$set)等,也可以理解为 SQL 语句中的 update 语句中的 set 后面的内容。
- (3) upsert:如果不存在 update 的记录,是否插入 objNew,true 表示插入,默认是 false,表示不插入。
- (4) multi: MongoDB 默认是 false,只更新找到的第一条记录,如果这个参数为 true,就会把按条件查出来的多条记录全部更新。默认是 false,只修改匹配到的第一条数据。

上面各个参数中, criteria 和 objNew 是必选参数, upsert 和 multi 是可选参数。 这里给出一个实例, 语句如下:

```
>db.student.update({sname: 'lisi'}, {$set: {sage: 30}}, false, true)
```

该命令相当于关系数据库的 SQL 语句"update student set sage=30 where sname='lisi';"。执行该命令的屏幕截图如图 6-17 所示。

```
> db.student.update({sname:'lisi'},{$set:{sage:30}},false,true)
WriteResult({ "nMatched" : 1, "nUpserted" : 0, "nModified" : 1 })
> db.student.find({sname:'lisi'})
{ "_id" : ObjectId("577b3a1dacae8736eab65abf"), "sname" : "lisi", "sage" : 30 }
>
```

图 6-17 修改数据

#### 6) 删除数据

```
>db.student.remove({sname: 'chenliu'})
```

该命令相当于关系数据库的 SQL 语句 delete from student where sname='chenliu'。 执行该命令过程的屏幕截图如图 6-18 所示。

图 6-18 删除数据

#### 7) 删除集合

```
>db.student.drop()
```

执行该命令过程的屏幕截图如图 6-19 所示。

```
> show collections
student
system.indexes
> db.student.drop()
true
> show collections
system.indexes
>
```

图 6-19 删除集合

## 4. 退出 MongoDB Shell 模式

可以输入如下命令退出 MongoDB Shell 模式:

```
>exit
```

也可以直接按键盘上的 Ctrl+C 键,退出 Shell 命令模式。

## 6.2.4 Java API 编程实例

编写 Java 程序访问 MongoDB 数据库时,首先,需要下载 Java MongoDB Driver 驱动 JAR 包,Java MongoDB Driver 下载地址如下:

```
http://central.maven.org/maven2/org/mongodb/mongo-java-driver/3.2.2/mongo-java-driver
-3.2.2.jar
```

可以在 Linux 系统中,打开浏览器,访问该网址下载 Java MongoDB Driver。或者,也可以直接访问本书官网的"下载专区",到"软件"目录中,把名称为 mongo-java-driver-3. 2. 2. jar 的文件下载到 Linux 本地文件系统中,默认的下载文件保存目录是"~/下载"或者~/Downloads。

然后就可以打开 Eclipse,参照第 4 章中介绍的 Eclipse 编程方法,新建一个 Java 工程, 在工程中导入刚刚下载的 JAR 包,然后,在工程中新建一个 MongoDBExample. java 文件, 输入如下代码,直接在 Eclipse 中编译运行即可。

```
import java.util.ArrayList;
import java.util.List;
import org.bson.Document;
import com.mongodb.MongoClient;
import com.mongodb.client.MongoCollection;
import com.mongodb.client.MongoCursor;
import com.mongodb.client.MongoDatabase;
import com.mongodb.client.model.Filters;
public class TestMongoDB {
   /**
    * @param args
   public static void main(String[] args) {
                    //插入数据。执行插入时,可将其他三句函数调用语句注释,下同
//
     insert();
                    //查找数据
     find();
     update();
                   //更新数据
//
     delete(); //删除数据
//
   }
   /**
    * 返回指定数据库中的指定集合
    * @ param dbname 数据库名
    * @ param collectionname 集合名
    * @return
   //MongoDB 无须预定义数据库和集合,在使用的时候会自动创建
```

```
public static MongoCollection < Document > getCollection (String dbname, String
 collectionname) {
   //实例化一个 mongo 客户端,服务器地址:localhost(本地),端口号:27017
   MongoClient mongoClient new MongoClient ("localhost", 27017);
   //实例化一个 mongo 数据库
   MongoDatabase mongoDatabase=mongoClient.getDatabase(dbname);
   //获取数据库中某个集合
   MongoCollection < Document > collection = mongoDatabase.getCollection
    (collectionname);
   return collection;
/**
 * 插入数据
public static void insert() {
   try{
       //连接 MongoDB,指定连接数据库名,指定连接表名
       MongoCollection < Document > collection = getCollection ("School",
                     //数据库名:School,集合名:student
       "student");
       //实例化一个文档,文档内容为{sname: 'Mary', sage: 25},如果还有其他字段,可以
         继续追加 append
       Document doc1=new Document ("sname", "Mary").append ("sage", 25);
       //实例化一个文档,文档内容为{sname: 'Bob', sage: 20}
       Document doc2=new Document ("sname", "Bob") .append ("sage", 20);
       List < Document > documents = new ArrayList < Document > ();
       //将 doc1、doc2加入到 documents列表中
       documents.add(doc1);
       documents.add(doc2);
       //将 documents 插入集合
       collection.insertMany(documents);
       System.out.println("插入成功");
    }catch (Exception e) {
       System.err.println(e.getClass().getName()+": "+e.getMessage());
/**
* 查询数据
* /
public static void find() {
   try{
       MongoCollection < Document > collection = getCollection ("School",
                        //数据库名:School,集合名:student
       "student");
       //通过游标遍历检索出的文档集合
```

```
//
           MongoCursor < Document > cursor = collection.find (new Document ("sname", "Mary")).
           projection(new Document("sname", 1).append("sage", 1).append("_id", 0)).
           iterator(); //find 查询条件: sname='Mary'. projection 筛选:显示 sname 和 sage,
           不显示_id(_id默认会显示)
            //查询所有数据
            MongoCursor< Document> cursor= collection.find().iterator();
            while(cursor.hasNext()){
                System.out.println(cursor.next().toJson());
        }catch (Exception e) {
            System.err.println(e.getClass().getName()+": "+e.getMessage());
    /**
       更新数据
   public static void update() {
        try{
            MongoCollection < Document > collection = getCollection ("School",
                             //数据库名:School,集合名:student
            "student");
            //更新文档,将文档中 sname= 'Mary'的文档修改为 sage= 22
            collection.updateMany(Filters.eq("sname", "Mary"), new Document
             ("$ set", new Document ("sage", 22)));
            System.out.println("更新成功!");
        }catch (Exception e) {
            System.err.println(e.getClass().getName()+": "+e.getMessage());
    /**
     * 删除数据
     * /
    public static void delete() {
        try{
           MongoCollection < Document > collection = getCollection ("School", "student");
                //数据库名:School,集合名:student
                //删除符合条件的第一个文档
            collection.deleteOne(Filters.eq("sname", "Bob"));
            //删除所有符合条件的文档
            //collection.deleteMany (Filters.eq("sname", "Bob"));
            System.out.println("删除成功!");
        }catch (Exception e) {
            System.err.println(e.getClass().getName()+": "+e.getMessage());
}
```

上述代码也可以直接从本书官网的"下载专区"下载,位于"代码"目录的"第6章"子目录,文件名是 MongoDBExample. java。

每次在 Eclipse 中执行完该程序,都可以在 Linux 系统的 MongoDB Shell 模式下查看结果。例如,在 Eclipse 执行完更新操作后,在 MongoDB Shell 模式下输入命令 db. student. find(),就可以查看 student 集合的所有数据(见图 6-20)。

```
> db.student.find() 更新操作前
{ "_id" : ObjectId("577c7c7fb1fa851712a95a77"), "sname" : "Mary", "sage" : 25 }
{ "_id" : ObjectId("577c7c7fb1fa851712a95a78"), "sname" : "Bob", "sage" : 20 }
> db.student.find() 更新操作后
{ "_id" : ObjectId("577c7c7fb1fa851712a95a77"), "sname" : "Mary", "sage" : 22 }
{ "_id" : ObjectId("577c7c7fb1fa851712a95a78"), "sname" : "Bob", "sage" : 20 }
```

图 6-20 查看 student 集合的所有数据

## 6.3 本章小结

传统的关系数据库可以较好地支持结构化数据存储和管理,但是,Web 2.0 的迅猛发展以及大数据时代的到来,使关系数据库的发展越来越力不从心。在大数据时代,数据类型繁多,包括结构化数据和各种非结构化数据,其中,非结构化数据的比例更是高达 90%以上。因此,在新的应用需求驱动下,各种新型的 NoSQL 数据库不断涌现,并逐渐获得市场的青睐。NoSQL 数据库主要包括键值数据库、列族数据库、文档数据库和图数据库 4 种类型,前面在第 5 章介绍的 HBase 就属于列族数据库。

键值数据库和文档数据库是两种应用比较广泛的 NoSQL 数据库,因此,本章选取了两个具有代表性的产品进行介绍,包括键值数据库 Redis 和文档数据库 MongoDB,详细介绍了这两种数据库的安装和使用方法,并给出了编程实例。

# MapReduce 基础编程

MapReduce 是 谷 歌 公 司 的 核 心 计 算 模 型, Hadoop 开 源 实 现 了 MapReduce。 MapReduce 将复杂的、运行于大规模集群上的并行计算过程高度抽象到了两个函数: Map和 Reduce, 并极大地方便了分布式编程工作, 编程人员在不会分布式并行编程的情况下, 也可以很容易将自己的程序运行在分布式系统上, 完成海量数据的计算。

本章以一个词频统计任务为主线,详细介绍 MapReduce 基础编程方法。首先,阐述词 频统计的任务要求;其次,介绍 MapReduce 程序的具体编写方法;最后,阐述如何编译运行程序。

## 7.1 词频统计任务要求

首先在 Linux 系统本地创建两个文件,即文件 wordfile1.txt 和 wordfile2.txt。在实际应用中,这两个文件可能会非常大,会被分布存储到多个节点上。但是,为了简化任务,这里的两个文件只包含几行简单的内容。需要说明的是,针对这两个小数据集样本编写的MapReduce 词频统计程序,不做任何修改,就可以用来处理大规模数据集的词频统计。

文件 wordfile1. txt 的内容如下:

```
I love Spark
I love Hadoop
```

文件 wordfile2. txt 的内容如下:

```
Hadoop is good
Spark is fast
```

假设 HDFS 中有一个 input 文件夹,并且文件夹为空,请把文件 wordfile1. txt 和 wordfile2. txt 上传到 HDFS 中的 input 文件夹下。现在需要设计一个词频统计程序,统计 input 文件夹下所有文件中每个单词的出现次数,也就是说,程序应该输出如下形式的结果:

```
fast 1
good 1
Hadoop 2
```

```
I 2
is 2
love 2
Spark 2
```

## 7.2 MapReduce 程序编写方法

编写 MapReduce 程序来实现词频统计功能,主要包括以下 3 个步骤。

- (1) 编写 Map 处理逻辑。
- (2) 编写 Reduce 处理逻辑。
- (3) 编写 main 方法。

## 7.2.1 编写 Map 处理逻辑

MapReduce 程序包括 Map 阶段和 Reduce 阶段。在 Map 阶段,文件 wordfile1. txt 和文件 wordfile2. txt 中的文本数据被读入,以<key,value>的形式提交给 Map 函数进行处理,其中,key 是当前读取到的行的地址偏移量,value 是当前读取到的行的内容。<key,value>提交给 Map 函数以后,就可以运行自定义的 Map 处理逻辑,对 value 进行处理,然后以特定的键值对的形式进行输出,这个输出将作为中间结果,继续提供给 Reduce 阶段作为输入数据。以下是 Map 处理逻辑的具体代码:

```
public static class TokenizerMapper extends Mapper<Object, Text, Text, IntWritable>{
    private static final IntWritable one=new IntWritable(1);
    private Text word=new Text();
    public TokenizerMapper() {
    }
    public void map(Object key, Text value, Mapper<Object, Text, Text,
    IntWritable>.Context context) throws IOException, InterruptedException {
        StringTokenizer itr=new StringTokenizer(value.toString());
        while (itr.hasMoreTokens()) {
            this.word.set(itr.nextToken());
            context.write(this.word, one);
        }
    }
}
```

## 7.2.2 编写 Reduce 处理逻辑

Map 阶段得到的中间结果,经过 Shuffle 阶段(分区、排序、合并)以后,分发给对应的 Reduce 任务去处理。对于 Reduce 阶段而言,输入是<key, value-list>形式,例如,<'Hadoop',<1,1>>。Reduce 函数就是对输入中的 value-list 进行求和,得到词频统计结

#### 果。下面给出 Reduce 处理逻辑的具体代码:

```
public static class IntSumReducer extends Reducer<Text, IntWritable, Text, IntWritable>{
    private IntWritable result=new IntWritable();
    public IntSumReducer() {
    }
    public void reduce(Text key, Iterable<IntWritable>values, Reducer
    <Text, IntWritable, Text, IntWritable>.Context context) throws
    IOException, InterruptedException {
        int sum=0;
        IntWritable val;
        for(Iterator i$=values.iterator(); i$.hasNext(); sum+=val.get()) {
        val=(IntWritable)i$.next();
      }
      this.result.set(sum);
      context.write(key, this.result);
}
```

## 7.2.3 编写 main 方法

为了让 TokenizerMapper 类和 IntSumReducer 类能够协同工作,完成最终的词频统计任务,需要在主函数中通过 Job 类设置 Hadoop 程序运行时的环境变量,具体代码如下:

```
public static void main (String[] args) throws Exception {
    Configuration conf=new Configuration();
    String[]otherArgs= (new GenericOptionsParser(conf, args)).getRemainingArgs();
    if (otherArgs.length<2) {
        System.err.println("Usage: wordcount<in>[<in>...]<out>");
        System.exit(2);
                                                         //设置环境参数
    Job job=Job.getInstance(conf, "word count");
                                                         //设置整个程序的类名
    job.setJarByClass(WordCount.class);
    job.setMapperClass(WordCount.TokenizerMapper.class); //添加 Mapper 类
                                                         //添加 Reducer 类
    job.setReducerClass(WordCount.IntSumReducer.class);
                                                         //设置输出类型
    job.setOutputKeyClass(Text.class);
                                                         //设置输出类型
    job.setOutputValueClass(IntWritable.class);
    for(int i=0; i<otherArgs.length-1;++i) {</pre>
        FileInputFormat.addInputPath(job, new Path(otherArgs[i]));
                                                         //设置输入文件
```

```
FileOutputFormat.setOutputPath(job, new Path(otherArgs[otherArgs.length-1]));//设置输出文件
System.exit(job.waitForCompletion(true)?0:1);
}
```

## 7.2.4 完整的词频统计程序

在编写词频统计 Java 程序时,需要新建一个名称为 WordCount. java 的文件,该文件包含了完整的词频统计程序代码,具体如下:

```
import java.io.IOException;
import java.util.Iterator;
import java.util.StringTokenizer;
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.Path;
import org.apache.hadoop.io.IntWritable;
import org.apache.hadoop.io.Text;
import org.apache.hadoop.mapreduce.Job;
import org.apache.hadoop.mapreduce.Mapper;
import org.apache.hadoop.mapreduce.Reducer;
import org.apache.hadoop.mapreduce.lib.input.FileInputFormat;
import org.apache.hadoop.mapreduce.lib.output.FileOutputFormat;
import org.apache.hadoop.util.GenericOptionsParser;
public class WordCount {
    public WordCount() {
     public static void main(String[] args) throws Exception {
        Configuration conf=new Configuration();
        String[] otherArgs= (new GenericOptionsParser(conf, args)).
        getRemainingArgs();
        if (otherArgs.length<2) {
             System.err.println("Usage: wordcount<in>[<in>...]<out>");
             System.exit(2);
        Job job=Job.getInstance(conf, "word count");
        job.setJarByClass(WordCount.class);
        job.setMapperClass(WordCount.TokenizerMapper.class);
        job.setCombinerClass (WordCount.IntSumReducer.class);
        job.setReducerClass(WordCount.IntSumReducer.class);
        job.setOutputKeyClass(Text.class);
        job.setOutputValueClass(IntWritable.class);
        for(int i=0; i<otherArgs.length-1;++i) {</pre>
            FileInputFormat.addInputPath(job, new Path(otherArgs[i]));
        }
```

```
FileOutputFormat.setOutputPath(job, new Path(otherArgs[otherArgs.
        length-1]));
        System.exit(job.waitForCompletion(true)?0:1);
    public static class TokenizerMapper extends Mapper < Object, Text, Text,
    IntWritable> {
        private static final IntWritable one=new IntWritable(1);
        private Text word=new Text();
        public TokenizerMapper() {
        public void map (Object key, Text value, Mapper<Object, Text, Text,
        IntWritable>.Context context) throws IOException, InterruptedException {
             StringTokenizer itr=new StringTokenizer(value.toString());
             while(itr.hasMoreTokens()) {
                 this.word.set(itr.nextToken());
                 context.write(this.word, one);
             }
public static class IntSumReducer extends Reducer Text, IntWritable, Text, IntWritable> {
       private IntWritable result=new IntWritable();
        public IntSumReducer() {
        public void reduce (Text key, Iterable < IntWritable > values, Reducer
        <Text, IntWritable, Text, IntWritable>.Context context) throws
        IOException, InterruptedException {
             int sum=0;
             IntWritable val:
             for(Iterator i$=values.iterator(); i$.hasNext(); sum+=val.get()) {
                 val= (IntWritable) i$.next();
             this.result.set(sum);
             context.write(key, this.result);
}
```

上述代码可以从本书官网的"下载专区"中下载,进入"下载专区"后,把"代码"目录的 "第7章"子目录中的 WordCount. java 文件下载到本地。

## 7.3 编译打包程序

可以采用两种方式对上面编写的 WordCount 代码进行编译打包。

- (1) 使用命令行编译打包词频统计程序。
- (2) 使用 Eclipse 编译打包词频统计程序。

## 7.3.1 使用命令行编译打包词频统计程序

在第3章中已经安装了Java程序(JDK),因此,这里可以直接用JDK包中的工具对代码进行编译。

首先在 Linux 系统中打开一个终端,把 Hadoop 的安装目录设置为当前工作目录,命令如下:

\$cd /usr/local/hadoop

然后执行如下命令,让 javac 编译程序可以找到 Hadoop 相关的 JAR 包:

\$export

CLASSPATH="/usr/local/hadoop/share/hadoop/common/hadoop-common-2.7.1.jar:/usr/local/hadoop/share/hadoop/mapreduce/hadoop-mapreduce-client-core-2.7.1.jar:/usr/local/hadoop/share/hadoop/common/lib/commons-cli-1.2.jar:\$CLASSPATH"

接下来就可以执行 javac 命令来编译程序(这里假设 WordCount. java 文件被放在/usr/local/hadoop 目录下):

\$javac WordCount.java

如果系统环境找不到 javac 程序的位置,那么使用 JDK 中的绝对路径。

编译之后,在文件夹下可以发现有 3 个. class 文件,这是 Java 的可执行文件。此时,需要将它们打包并命名为 WordCount. jar,命令如下:

\$jar - cvf WordCount.jar \* .class

## 7.3.2 使用 Eclipse 编译运行词频统计程序

上面介绍了如何使用命令行编译打包词频统计程序,实际上,也可以使用另外一种方式,即使用 Eclipse 编译运行词频统计程序。

### 1. 在 Eclipse 中创建项目

首先启动 Eclipse,启动以后会弹出如图 7-1 所示的界面,提示设置工作空间(workspace)。可以直接采用默认的设置/home/hadoop/workspace,单击 OK 按钮。可以看出,由于当前是采用 hadoop 用户登录了 Linux 系统,因此,默认的工作空间目录位于 hadoop 用户目录/home/hadoop 下。

Eclipse 启动以后,呈现的界面如图 7-2 所示。

选择 File New Java Project 命令,开始创建一个 Java 工程,弹出如图 7-3 所示的界面。

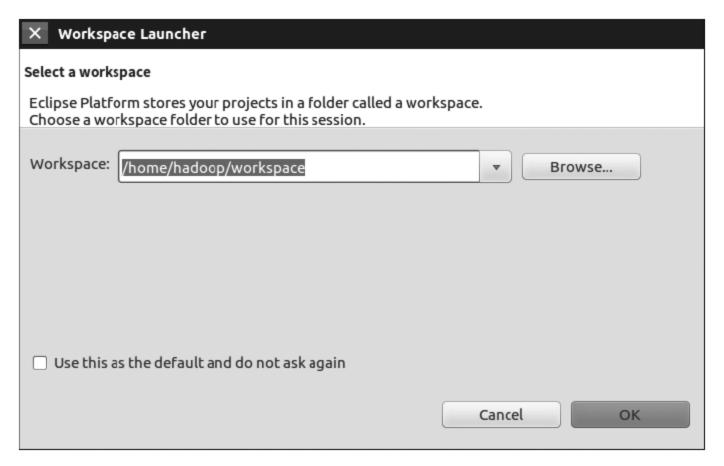


图 7-1 Eclipse 工作空间设置界面

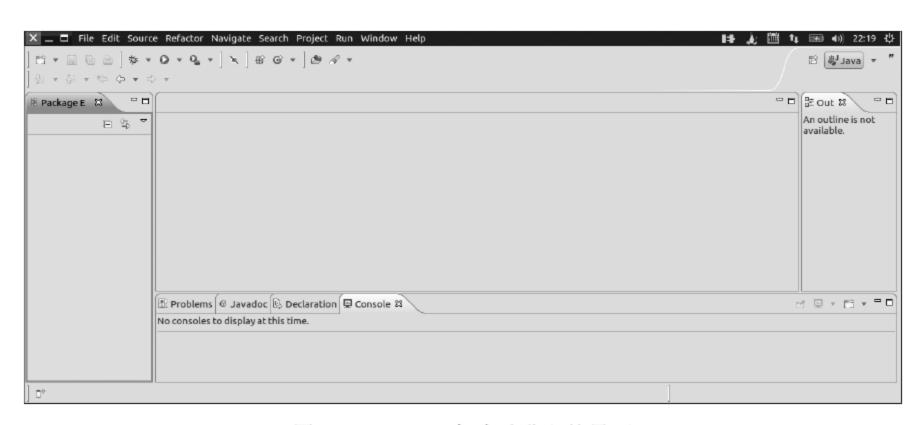


图 7-2 Eclipse 启动后进入的界面

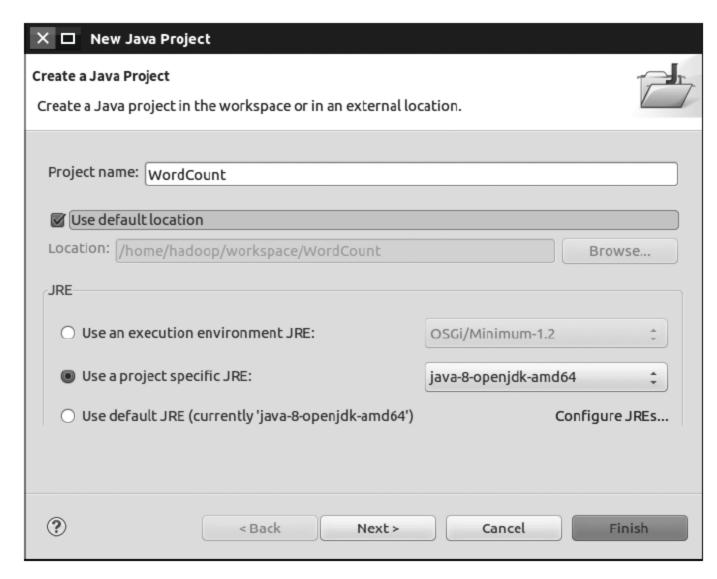


图 7-3 新建 Java 工程界面

在 Project name 后面的文本框中输入工程名称 WordCount,选中 Use default location 复选框,让这个 Java 工程的所有文件都保存到/home/hadoop/workspace/WordCount 目录下。在 JRE 这个选项卡中,可以选择当前的 Linux 系统中已经安装好的 JDK,如 java-8-openjdk-amd64;然后单击界面底部的 Next 按钮,进入下一步的设置。

#### 2. 为项目添加需要用到的 JAR 包

进入下一步的设置以后,会弹出如图 7-4 所示的界面。

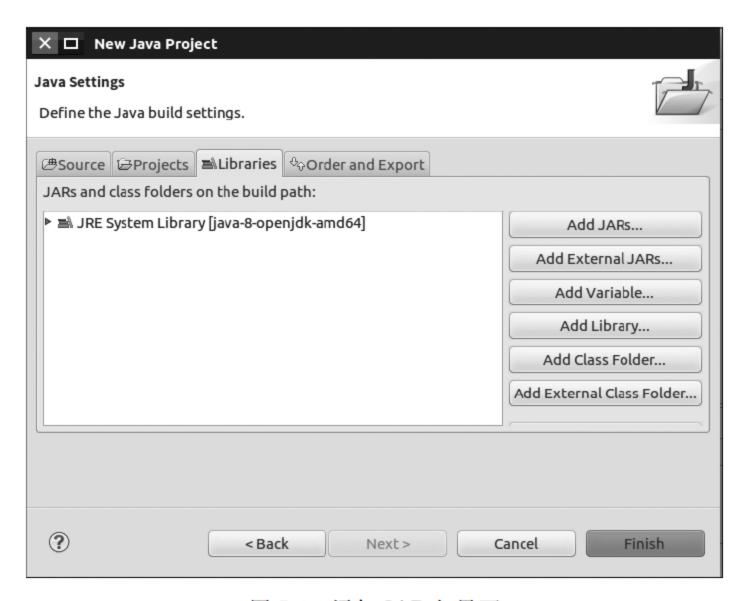


图 7-4 添加 JAR 包界面

需要在这个界面中加载该 Java 工程所需要用到的 JAR 包,这些 JAR 包中包含了可以访问 HDFS 的 Java API。这些 JAR 包都位于 Linux 系统的 Hadoop 安装目录下,对于本书而言,就是在/usr/local/hadoop/share/hadoop 目录下。单击界面中的 Libraries 选项卡,然后单击界面右侧的 Add External JARs 按钮,弹出如图 7-5 所示的界面。

在该界面中,上面有一排目录按钮(即 usr、local、hadoop、share、hadoop、mapreduce 和 lib),当单击某个目录按钮时,就会在下面列出该目录的内容。

为了编写一个 MapReduce 程序,一般需要向 Java 工程中添加以下 JAR 包。

- (1) /usr/local/hadoop/share/hadoop/common 目录下的 hadoop-common-2.7.1. jar 和 haoop-nfs-2.7.1. jar。
  - (2) /usr/local/hadoop/share/hadoop/common/lib 目录下的所有 JAR 包。
- (3) /usr/local/hadoop/share/hadoop/mapreduce 目录下的 hadoop-mapreduce-client-app-2.7.1. jar 等 JAR 包,具体如图 7-6 所示。
  - (4) /usr/local/hadoop/share/hadoop/mapreduce/lib 目录下的所有 JAR 包。

例如,如果要把/usr/local/hadoop/share/hadoop/common 目录下的 hadoop-common-2.7.1. jar 和 haoop-nfs-2.7.1. jar 添加到当前的 Java 工程中,可以在界面中单击相应的目录按钮,进入到 common 目录,然后,界面会显示出 common 目录下的所有内容(见图 7-7)。

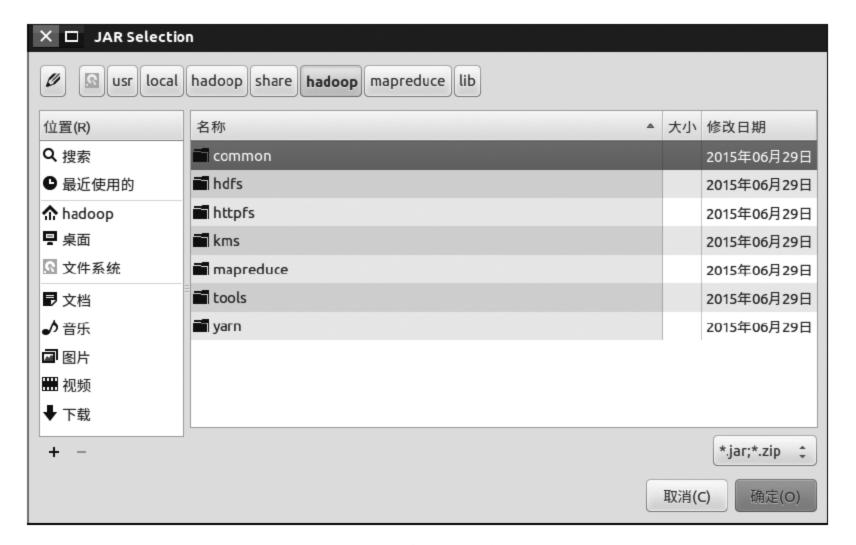


图 7-5 选择 JAR 包界面

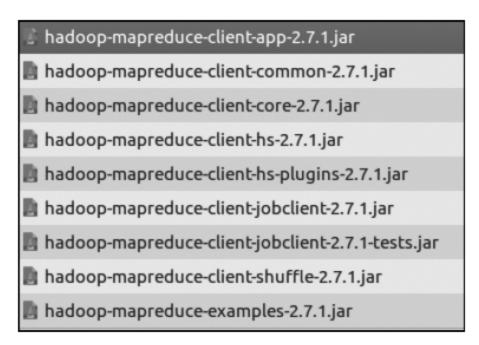


图 7-6 需要添加的 JAR 包

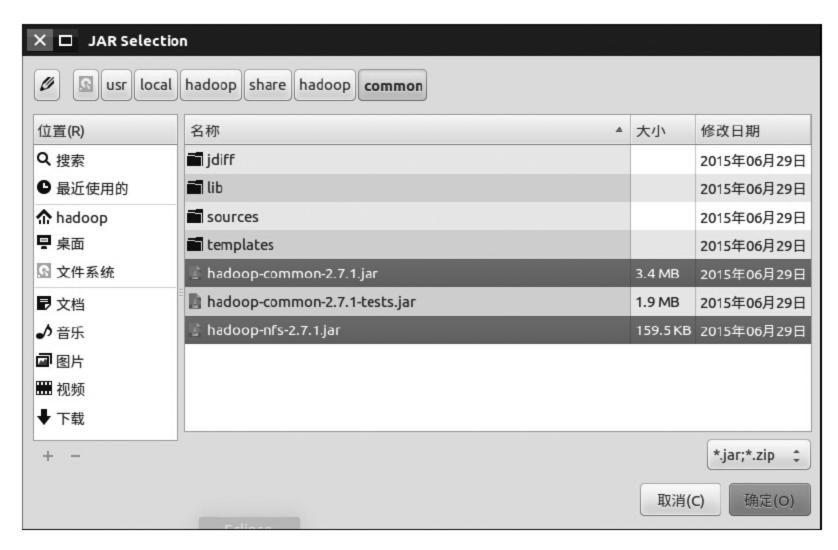


图 7-7 添加 common 目录下的 JAR 包

在界面中选中 hadoop-common-2. 7. 1. jar 和 haoop-nfs-2. 7. 1. jar,然后单击界面右下角的"确定"按钮,就可以把这两个 JAR 包增加到当前 Java 工程中,出现的界面如图 7-8 所示。

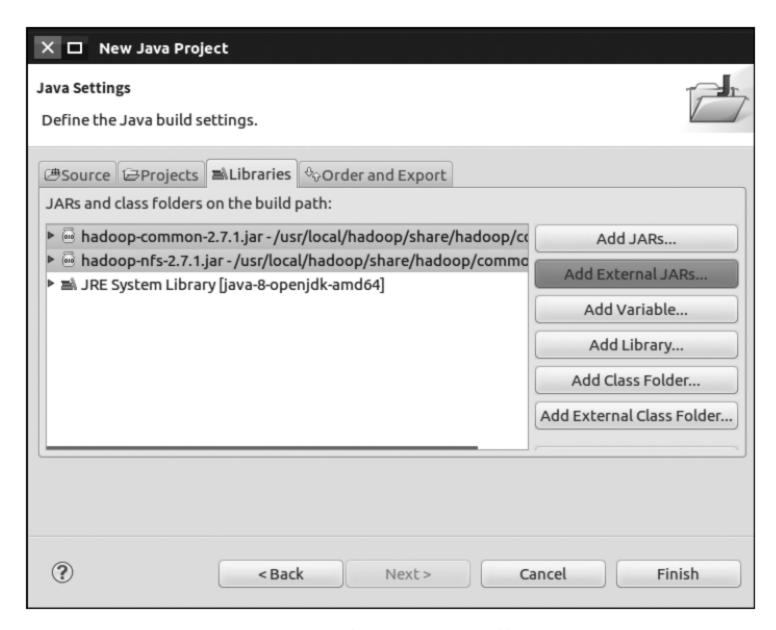


图 7-8 添加 JAR 包后的结果

从这个界面中可以看出,hadoop-common-2.7.1.jar 和 haoop-nfs-2.7.1.jar 已经被添加到当前 Java 工程中;然后按照类似的操作方法,可以再次单击 Add External JARs 按钮,把剩余的其他 JAR 包都添加进来。需要注意的是,当需要选中某个目录下的所有 JAR 包

时,可以使用 Ctrl+A 键进行全选操作。全部添加完毕以后,可以单击界面右下角的 Finish 按钮, 完成 Java 工程 WordCount 的创建。

#### 3. 编写 Java 应用程序

下面编写一个 Java 应用程序,即 WordCount. java。在 Eclipse 工作界面左侧的 ackage Explorer 面板中(见图 7-9)找到刚才创建好的工程名称 WordCount,然后在该工程名称上右击,在弹出的 菜单中选择 New→Class 命令。

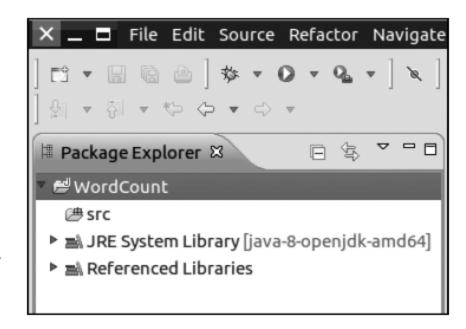


图 7-9 Package Explorer 面板

选择 New→Class 命令以后会出现如图 7-10 所示的界面。

在该界面中,只需要在 Name 后面的文本框中输入新建的 Java 类文件的名称,这里采用名称 WordCount,其他都可以采用默认设置;然后单击界面右下角 Finish 按钮,出现如图 7-11 所示的界面。

可以看出, Eclipse 自动创建了一个名为 WordCount. java 的源代码文件, 并且包含了代码 public class WordCount{},清空该文件里面的代码,然后在该文件中输入 7.2.4 节中已

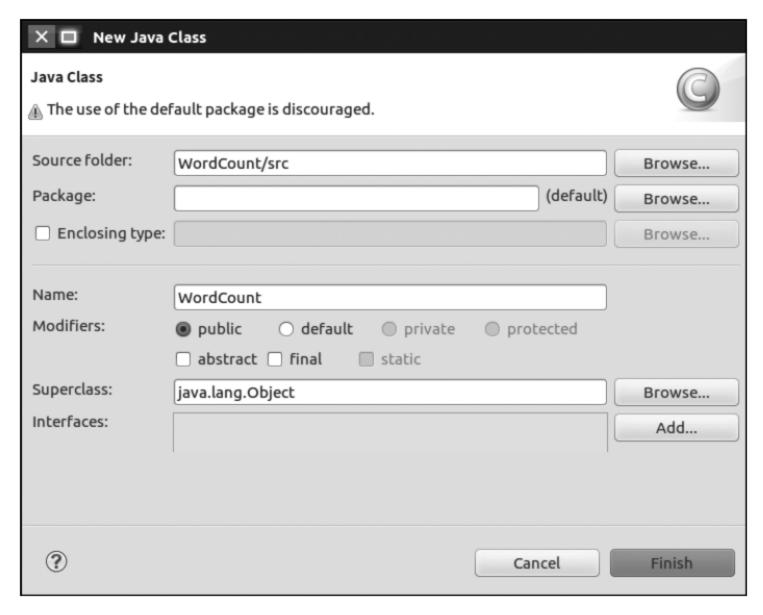


图 7-10 新建 Java Class 界面

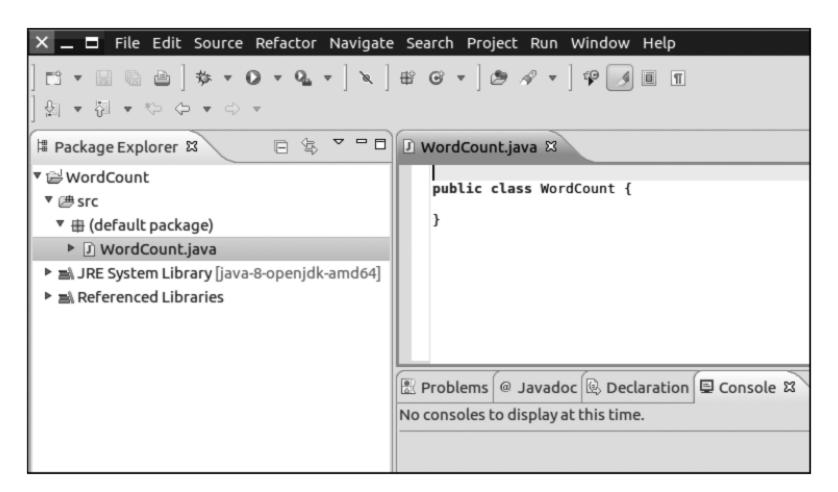


图 7-11 WordCount. java 文件编辑

经给出的完整的词频统计程序代码。

词频统计程序代码复制进去以后,可能会出现如图 7-12 所示的错误。

图 7-12 Eclipse 给出的错误信息

关于这个错误的原因和解决方法,之前已经在第5章中做过介绍,可以采用之前的方法解决这个错误,这里不再赘述。

### 4. 编译打包程序

现在就可以编译上面编写的代码。可以直接单击 Eclipse 工作界面上部的运行程序的快捷按钮,当把鼠标移动到该按钮上时,在弹出的菜单中选择 Run as→Java Application 命令,如图 7-13 所示。

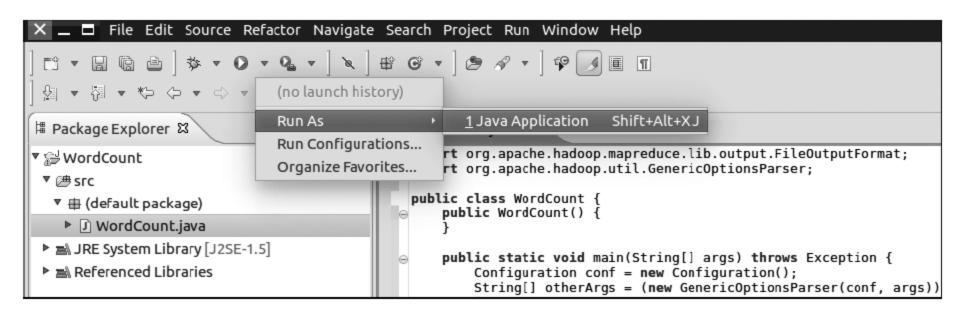


图 7-13 编译运行程序

然后会弹出如图 7-14 所示的界面。

单击界面右下角的 OK 按钮,开始运行程序。程序运行结束后,会在底部的 Console 面板中显示运行结果信息(见图 7-15)。

下面就可以把 Java 应用程序打包生成 JAR 包,部署到 Hadoop 平台上运行。在第 4 章中,已 经在 Hadoop 安装目录下新建了一个名称为 myapp 的目录,用来存放我们自己编写的 Hadoop 应用程序,现在可以把词频统计程序放在 myapp 目录下。

首先在 Eclipse 工作界面左侧的 Package Explorer 面板中的工程名称 WordCount 上右击, 从弹出的菜单中选择 Export,如图 7-16 所示。

然后会弹出如图 7-17 所示的界面。

在该界面中,选择 Runnable JAR file,然后单击 Next 按钮,弹出如图 7-18 所示的界面。



图 7-14 Save and Launch 界面

在该界面中, Launch configuration 用于设置

生成的 JAR 包被部署启动时运行的主类,需要在下拉列表中选择刚才配置的类 WordCount (6)-WordCount。在 Export destination 下拉列表中需要设置 JAR 包要输出保存到哪个目录,例如,这里设置为/usr/local/hadoop/myapp/WordCount.jar。在 Library handling 下面选择的 Extract required libraries into generated JAR 单选按钮;然后单击 Finish 按钮,会出现如图 7-19 所示的界面。

```
_ _
import org.apache.hadoop.mapreduce.lib.output.FileOutputFormat;
   import org.apache.hadoop.util.GenericOptionsParser;
   public class WordCount {
       public WordCount() {
       public static void main(String[] args) throws Exception {
           Configuration conf = new Configuration();
           String[] otherArgs = (new GenericOptionsParser(conf, args)).getRemainingArgs();
           if(otherArgs.length < 2) {
               System.err.println("Usage: wordcount <in> [<in>...] <out>");
               System.exit(2);
           Job job = Job.getInstance(conf, "word count");
           job.setJarByClass(WordCount.class);
           job.setMapperClass(WordCount.TokenizerMapper.class);
           iob.setCombinerClass(WordCount.IntSumReducer.class);
🔐 Problems @ Javadoc 🔯 Declaration 星 Console 🛭
                                                                          <terminated>WordCount (6) [Java Application] /usr/lib/jvm/java-8-openjdk-amd64/bin/java (2017-1-30下午7:09:31)
Usage: wordcount <in> [<in>...] <out>
```

图 7-15 程序运行结果信息

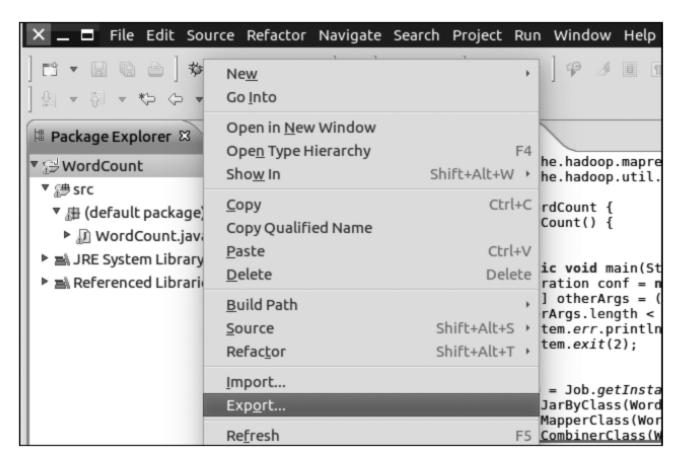


图 7-16 导出程序

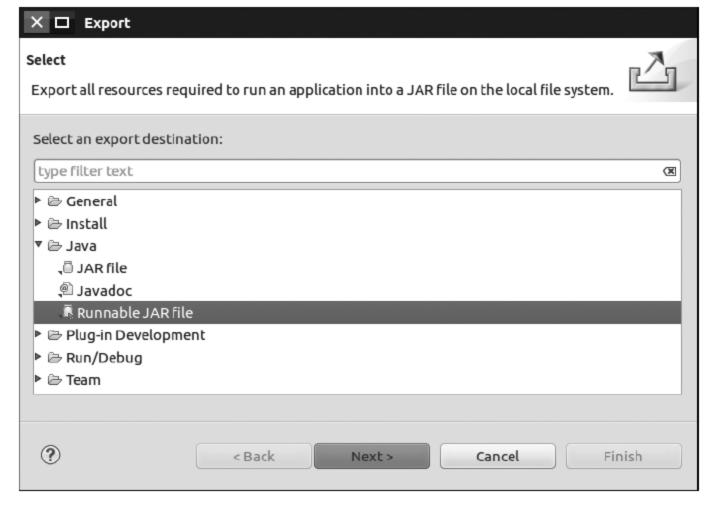


图 7-17 导出程序类型选择

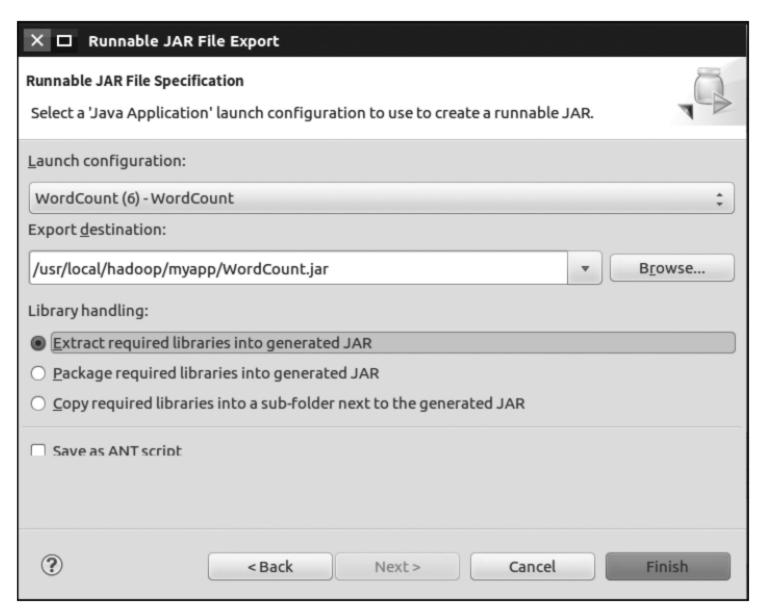


图 7-18 导出程序选项设置

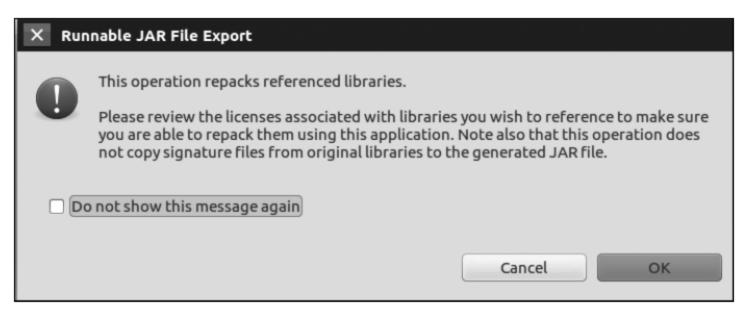


图 7-19 导出程序时的提示信息

可以忽略该界面的提示信息,直接单击界面右下角的 OK 按钮,启动打包过程。打包过程结束后,会出现一个警告信息界面,如图 7-20 所示。

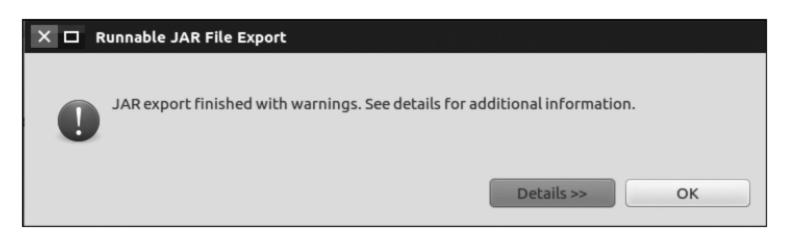


图 7-20 导出程序时的警告信息

可以忽略该界面的警告信息,直接单击界面右下角的 OK 按钮。至此,已经顺利把 WordCount 工程打包生成了 WordCount. jar。可以到 Linux 系统中查看一下生成的 WordCount. jar 文件,可以在 Linux 的终端中执行如下命令:

\$cd /usr/local/hadoop/myapp

\$ls

可以看到,/usr/local/hadoop/myapp 目录下已经存在一个 WordCount. jar 文件。

## 7.4 运行程序

运行程序之前,需要启动 Hadoop,命令如下:

\$cd /usr/local/hadoop

\$./sbin/start-dfs.sh

启动 Hadoop 之后,需要首先删除 HDFS 中与当前 Linux 用户 hadoop 对应的 input 和 output 目录(即 HDFS 中的/user/hadoop/input 和/user/hadoop/output 目录),这样确保 后面程序运行不会出现问题,具体命令如下:

\$cd /usr/local/hadoop

- \$./bin/hdfs dfs rm r input
- \$./bin/hdfs dfs rm r output

然后再在 HDFS 中新建与当前 Linux 用户 hadoop 对应的 input 目录,即/user/hadoop/input 目录,具体命令如下:

\$cd /usr/local/hadoop

\$./bin/hdfs dfs -mkdir input

然后把第 7.1 节中在 Linux 本地文件系统中新建的两个文件 wordfile1. txt 和wordfile2. txt(假设这两个文件位于/usr/local/hadoop 目录下),上传到 HDFS 中的/user/hadoop/input 目录下,命令如下:

\$cd /usr/local/hadoop

- \$./bin/hdfs dfs put ./wordfile1.txt input
- \$./bin/hdfs dfs put ./wordfile2.txt input

现在就可以在 Linux 系统中,使用 hadoop jar 命令运行程序,命令如下:

\$cd /usr/local/hadoop

\$./bin/hadoop jar ./myapp/WordCount.jar input output

上面命令执行以后,当运行顺利结束时,屏幕上会显示类似如下的信息:

…//这里省略若干屏幕信息

17/01/30 19:54:54 INFO mapreduce.Job: map 100% reduce 100%

```
17/01/30 19:54:54 INFO mapreduce.Job: Job job_local1874680376_0001 completed
successfully
17/01/30 19:54:54 INFO mapreduce.Job:Counters: 35
    File System Counters
        FILE: Number of bytes read=99579063
        FILE: Number of bytes written=101193318
        FILE: Number of read operations=0
        FILE: Number of large read operations=0
        FILE: Number of write operations=0
        HDFS: Number of bytes read=146
        HDFS: Number of bytes written= 47
        HDFS: Number of read operations=22
        HDFS: Number of large read operations=0
        HDFS: Number of write operations=5
    Map-Reduce Framework
        Map input records=6
        Map output records=12
        Map output bytes=104
        Map output materialized bytes=112
        Input split bytes=236
        Combine input records=12
        Combine output records=9
        Reduce input groups=7
        Reduce shuffle bytes=112
        Reduce input records=9
        Reduce output records=7
        Spilled Records=18
        Shuffled Maps=2
        Failed Shuffles=0
        Merged Map outputs=2
        GC time elapsed (ms) = 234
        Total committed heap usage (bytes) = 792342528
    Shuffle Errors
        BAD ID=0
        CONNECTION= 0
        IO ERROR=0
        WRONG LENGTH= 0
        WRONG MAP= 0
        WRONG REDUCE= 0
    File Input Format Counters
        Bytes Read=58
    File Output Format Counters
        Bytes Written= 47
```

词频统计结果已经被写入了 HDFS 的/user/hadoop/output 目录中,可以执行如下命令查看词频统计结果:

```
$cd /usr/local/hadoop
$./bin/hdfs dfs - cat output/*
```

上面命令执行后,会在屏幕上显示如下词频统计结果:

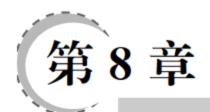
```
Hadoop 2
I 2
Spark 2
fast 1
good 1
is 2
love 2
```

至此,词频统计程序顺利运行结束。需要注意的是,如果要再次运行 WordCount. jar, 需要首先删除 HDFS 中的 output 目录,否则会报错。

## 7.5 本章小结

本章详细演示如何编写 MapReduce 程序实现词频统计功能。在编写 MapReduce 程序之前,需要先判断目标任务是否可以采用 MapReduce 编程。MapReduce 会把一个大的文件切分成多小片段进行分布式并行处理,最终对不同片段的处理结果进行汇总。很显然,词频统计任务是符合这个要求的,因此,可以采用 MapReduce 编写程序。

本章详细介绍 MapReduce 程序的具体编写方法,包括编写 Map 处理逻辑、Reduce 处理逻辑、main 方法等。最后,演示了如何使用 Eclipse 编译运行 Java 应用程序。通过本章的学习,可以形成对 MapReduce 编程方法的基本认识。如果要深入了解如何把各种任务转换成 MapReduce 程序,建议继续学习相关的进阶书籍。



# 数据仓库 Hive 的安装和使用

Hive 是一个基于 Hadoop 的数据仓库工具,可以用于对存储在 Hadoop 文件中的数据集进行数据整理、特殊查询和分析处理。Hive 的学习门槛比较低,因为它提供了类似于关系数据库 SQL 语言的查询语言——HiveQL,可以通过 HiveQL 语句快速实现简单的 MapReduce 统计, Hive 自身可以将 HiveQL 语句快速转换成 MapReduce 任务进行运行,而不必开发专门的 MapReduce 应用程序,因而十分适合数据仓库的统计分析。

本章首先介绍 Hive 的安装方法;然后介绍 Hive 的数据类型和基本操作;最后给出了一个 WordCount 应用实例,来展示 Hive 编程的优势。

## 8.1 Hive 的安装

本节介绍 Hive 的具体安装方法,包括下载安装文件、配置环境变量、修改配置文件,以及安装配置 MySQL 等。

## 8.1.1 下载安装文件

登录 Linux 系统(本书统一采用 hadoop 用户登录),打开浏览器,访问 Hive 官网 (http://www.apache.org/dyn/closer.cgi/hive/)下载安装文件 apache-hive-1. 2. 1-bin. tar. gz,把安装文件保存到"~/下载/"目录下;或者也可以直接到本书官网的"下载专区"中下载 Hive 安装文件,单击进入下载专区后,在"软件"这个文件夹中,找到文件 apache-hive-1. 2. 1-bin. tar. gz,下载到本地,保存到 Linux 系统的"~/下载"目录下(也就是"/home/hadoop/下载"目录)。需要说明的是,当前 Hive 官网已经提供 2. 0 以上版本的下载,但是,作为入门学习,安装 1. 2. 1 版本是没有问题的。

下载完安装文件以后,需要对文件进行解压。按照 Linux 系统使用的默认规范,用户安装的软件一般都是存放在/usr/local/目录下。在 Linux 系统中打开一个终端,执行如下命令:

\$sudo tar - zxvf ./apache-hive-1.2.1-bin.tar.gz - C /usr/local #解压到/usr/local中

\$cd /usr/local/

\$sudo mv apache-hive-1.2.1-bin hive

\$sudo chown -R hadoop:hadoop hive

#将文件夹名改为 hive #修改文件权限

## 8.1.2 配置环境变量

为了方便使用,可以把 hive 命令加入到环境变量 PATH 中,从而可以在任意目录下直接使用 hive 命令启动,使用 vim 编辑器打开~/. bashrc 文件进行编辑,命令如下:

\$vim ~/.bashrc

在该文件的最前面一行添加如下内容:

```
export HIVE_HOME=/usr/local/hive
export PATH= $PATH: $HIVE_HOME/bin
```

保存该文件并退出 vim 编辑器,然后运行如下命令使得配置立即生效:

\$source ~/.bashrc

## 8.1.3 修改配置文件

将/usr/local/hive/conf 目录下的 hive-default. xml. template 文件重命名为 hive-default. xml,命令如下:

```
$cd /usr/local/hive/conf
$sudo mv hive-default.xml.template hive-default.xml
```

同时,使用 vim 编辑器新建一个文件 hive-site. xml,命令如下:

```
$cd /usr/local/hive/conf
$vim hive-site.xml
```

在 hive-site. xml 中输入如下配置信息:

该配置文件可以直接从本书官网"下载专区"的"代码"目录的"第8章"子目录下载,文件名是 hive-site. xml。

## 8.1.4 安装并配置 MySQL

## 1. 安装 MySQL

这里采用 MySQL 数据库保存 Hive 的元数据,而不是采用 Hive 自带的 derby 来存储元数据,因此,需要安装 MySQL 数据库。可以参照附录 B,完成 MySQL 数据库的安装,这里不再赘述。

### 2. 下载 MySQL JDBC 驱动程序

为了让 Hive 能够连接到 MySQL 数据库,需要下载 MySQL JDBC 驱动程序。可以到 MySQL 官网(http://www.mysql.com/downloads/connector/j/)下载 mysql-connector-java-5.1.40. tar. gz;或者,也可以直接到本书官网的"下载专区"中下载,单击进入下载专区后,在"软件"这个文件夹中找到文件 mysql-connector-java-5.1.40. tar. gz,下载到本地,保存到 Linux 系统的"~/下载"目录下(也就是"/home/hadoop/下载"目录)。

然后在 Linux 系统中打开一个终端,在终端中执行如下命令解压缩文件:

```
$cd ~
$tar - zxvf mysql-connector-java-5.1.40.tar.gz #解压
$#下面将 mysql-connector-java-5.1.40-bin.jar复制到/usr/local/hive/lib目录下
$cp mysql-connector-java-5.1.40/mysql-connector-java-5.1.40-bin.jar/usr/local/hive/lib
```

## 3. 启动 MySQL

执行如下命令启动 MySQL,并进入"mysql>"命令提示符状态:

\$service mysql start

#启动 MySQL 服务

\$mysql -u root -p

#登录 MySQL 数据库

系统会提示输入 root 用户的密码,本书在安装 MySQL 数据库时,把 MySQL 的 root 用户密码设置为 hadoop,因此,这里可以输入 hadoop。

#### 4. 在 MySQL 中为 Hive 新建数据库

现在需要在 MySQL 数据库中新建一个名称为 hive 的数据库,用来保存 Hive 的元数据。MySQL 中的这个 hive 数据库,是与 Hive 的配置文件 hive-site. xml 中的 mysql://localhost:3306/hive 对应起来的,用来保存 Hive 元数据。在 MySQL 数据库中新建 hive 数据库的命令,需要在"mysql》"命令提示符下执行,具体如下:

mysql> create database hive;

### 5. 配置 MySQL 允许 Hive 接入

需要对 MySQL 进行权限配置,允许 Hive 连接到 MySQL。

mysql>grant all on \* .\* to hive@localhost identified by 'hive';
mysql>flush privileges;

上面的第一行命令,将 MySQL 的所有数据库的所有表的所有权限赋给 hive 用户,后面的 hive 是在配置文件 hive-site. xml 中事先设置的连接密码。第二行命令,用来刷新 MySQL 系统权限关系表。

#### 6. 启动 Hive

Hive 是基于 Hadoop 的数据仓库,会把用户输入的查询语句自动转换成为 MapReduce 任 务来执行,并把结果返回给用户。因此,启动 Hive 之前,需要先启动 Hadoop 集群,命令如下:

\$cd /usr/local/hadoop
\$./sbin/start-dfs.sh

然后再执行如下命令启动 Hive:

\$cd /usr/local/hive

\$./bin/hive

实际上,由于之前已经配置了环境变量 PATH,因此,也可以直接使用如下命令启动 Hive:

\$hive

在启动 Hive 时,有可能会出现 Hive metastore database is not initialized 的错误。出现这个错误的原因是,以前曾经安装了 Hive 或 MySQL,重新安装 Hive 和 MySQL 以后,导致版本、配置不一致。解决方法是,使用 schematool 工具。Hive 现在包含一个用于 Hive Metastore 架构操控的脱机工具——schematool。此工具可用于初始化当前 Hive 版本的 Metastore 架构。此外,它还可处理从较旧版本到新版本的架构升级。所以,为了解决上述错误,可以在终端中执行如下命令(注意,不是在"mysql》"命令提示下执行):

\$schematool - dbType mysql -initSchema

执行该命令后,再启动 Hive,就可以正常启动了。

## 8.2 Hive 的数据类型

Hive 支持关系数据库中的大多数基本数据类型,同时 Hive 还支持关系数据库中不常出现的的 3 种集合数据类型。表 8-1 中列举了 Hive 所支持的基本数据类型,包括多种不同长度的整型和浮点型数据类型、布尔类型以及无长度限制的字符串类型。另外,新版本(Hive v0.8.0 以上)中还支持时间戳数据类型和二进制数组数据类型。表 8-2 列举了 Hive中的列所支持的 3 种集合数据类型: struct、map、array。这里需要注意的是,表 8-2 的示例实际上调用的是内置函数。

类  型	描述	示 例
TINYINT	1B(8b)有符号整数	1
SMALLINT	2B(16b)有符号整数	1
INT	4B(32b)有符号整数	1
BIGINT	8B(64b)有符号整数	1
FLOAT	4B(32b)单精度浮点数	1.0
DOUBLE	8B(64b)双精度浮点数	1.0
BOOLEAN	布尔类型,true/false	true
STRING	字符串,可以指定字符集	"xmu"
TIMESTAMP	整数、浮点数或者字符串	1327882394(UNIX 新纪元秒)
BINARY	字节数组	[0,1,0,1,0,1,0,1]

表 8-1 Hive 的基本数据类型

表 8-2 Hive 的集合数据类型

类 型	描述	示 例
ARRAY	一组有序字段,字段的类型必须相同	Array(1,2)
MAP	一组无序的键/值对,键的类型必须是原子的,值可以是任何数据类型,同一个映射的键和值的类型必须相同	Map('a',1,'b',2)
STRUCT	一组命名的字段,字段类型可以不同	Struct('a',1,1,0)

## 8.3 Hive 基本操作

HiveQL是 Hive 的查询语言,和 SQL语言比较类似,对 Hive 的操作都是通过编写 HiveQL语句来实现的。接下来介绍一下 Hive 中常用的几个基本操作。

## 8.3.1 创建数据库、表、视图

- 1. 创建数据库
- (1) 创建数据库 hive。

hive>create database hive;

(2) 创建数据库 hive,因为 hive 已经存在,所以会抛出异常,加上 if not exists 关键字,则不会抛出异常。

hive>create database if not exists hive;

### 2. 创建表

(1) 在 hive 数据库中创建表 usr,含 3 个属性: id、name、age。

hive>use hive;

hive>create table if not exists usr(id bigint, name string, age int);

(2) 在 hive 数据库中创建表 usr,含 3 个属性: id、name、age。存储路径为/usr/local/hive/warehouse/hive/usr。

hive>create table if not exists hive.usr(id bigint,name string,age int)
> location'/usr/local/hive/warehouse/hive/usr';

(3) 在 hive 数据库中创建外部表 usr,含 3 个属性: id、name、age。可以读取路径/usr/local/data 下以","分隔的数据。

hive>create external table if not exists hive.usr(id bigint,name string,age int)
>row format delimited fields terminated by ','

>location'/usr/local/data';

(4) 在 hive 数据库中创建分区表 usr,含 3 个属性: id、name、age。还存在分区字段 sex。

hive>create table hive.usr(id bigint, name string, age int) partition by(sex boolean);

(5) 在 hive 数据库中创建分区表 usr1,它通过复制表 usr 得到。

hive>use hive;

hive>create table if not exists usrl like usr;

#### 3. 创建视图

创建视图 little\_usr,只包含 usr 表中的 id、age 属性。

hive>create view little\_usr as select id, age from usr;

## 8.3.2 删除数据库、表、视图

#### 1. 删除数据库

(1) 删除数据库 hive,如果不存在会出现警告。

hive>drop database hive;

(2) 删除数据库 hive,因为有 if exists 关键字,即使不存在也不会抛出异常。

hive>drop database if exists hive;

(3) 删除数据库 hive,加上 cascade 关键字,可以删除当前数据库和该数据库中的表。

hive>drop database if exists hive cascade;

## 2.删除表

删除表 usr,如果是内部表,元数据和实际数据都会被删除;如果是外部表,只删除元数据,不删除实际数据。

hive>drop table if exists usr;

### 3. 删除视图

删除视图 little\_usr。

hive>drop view if exists little\_usr;

## 8.3.3 修改数据库、表、视图

### 1. 修改数据库

为 hive 数据库设置 dbproperties 键值对属性值来描述数据库属性信息。

hive>alter database hive set dbproperties('edited-by'='lily');

### 2. 修改表

(1) 重命名表 usr 为 user。

hive>alter table usr rename to user;

(2) 为表 usr 增加新分区。

hive>alter table usr add if not exists partition(age=10); hive>alter table usr add if not exists partition(age=20);

(3) 删除表 usr 中的分区。

hive>alter table usr drop if exists partition (age=10);

(4) 把表 usr 中列名 name 修改为 username,并把该列置于 age 列后。

hive>alter table usr change name username string after age;

(5) 在对表 usr 分区字段之前,增加一个新列 sex。

hive>alter table usr add columns (sex boolean);

(6) 删除表 usr 中所有字段并重新指定新字段 newid、newname、newage。

hive>alter table usr replace columns (newid bigint, newname string, newage int);

(7) 为 usr 表设置 tblproperties 键值对属性值来描述表的属性信息。

hive>alter table usr set tblproperties('notes'='the columns in usr may be null except id');

#### 3. 修改视图

修改 little\_usr 视图元数据中的 tblproperties 属性信息。

hive>alter view little\_usr set tblproperties('create\_at'= 'refer to timestamp');

## 8.3.4 查看数据库、表、视图

#### 1. 查看数据库

(1) 查看 Hive 中包含的所有数据库。

hive>show databases;

(2) 查看 Hive 中以 h 开头的所有数据库。

hive>show databases like'h. \* ';

## 2. 查看表和视图

(1) 查看数据库 hive 中的所有表和视图。

hive>use hive;

hive>show tables;

(2) 查看数据库 hive 中以 u 开头的所有表和视图。

hive>show tables in hive like'u. \* ';

## 8.3.5 描述数据库、表、视图

## 1. 描述数据库

(1) 查看数据库 hive 的基本信息,包括数据库中文件的位置信息等。

hive>describe database hive;

(2) 查看数据库 hive 的详细信息,包括数据库的基本信息及属性信息等。

hive>describe database extended hive;

## 2. 描述表和视图

(1) 查看表 usr 和视图 little\_usr 的基本信息,包括列信息等。

hive>describe hive.usr;

hive>describe hive.little\_usr;

(2) 查看表 usr 和视图 little\_usr 的详细信息,包括列信息、位置信息、属性信息等。

hive>describe extended hive.usr;
hive>describe extended hive.little\_usr;

(3) 查看表 usr 中列 id 的信息。

hive>describe extended hive.usr.id;

# 8.3.6 向表中装载数据

(1) 把目录'/usr/local/data'下的数据文件中的数据装载进 usr 表并覆盖原有数据。

hive>load data local inpath '/usr/local/data' overwrite into table usr;

(2) 把目录'/usr/local/data'下的数据文件中的数据装载进 usr 表不覆盖原有数据。

hive>load data local inpath '/usr/local/data' into table usr;

(3) 把分布式文件系统目录'hdfs://master\_server/usr/local/data'下的数据文件数据装载进 usr 表并覆盖原有数据。

hive>load data inpath 'hdfs://master\_server/usr/local/data' overwrite into table usr;

# 8.3.7 查询表中数据

该命令和 SQL 语句完全相同,这里不再赘述。

# 8.3.8 向表中插入数据或从表中导出数据

(1) 向表 usr1 中插入来自 usr 表的数据并覆盖原有数据。

hive>insert overwrite table usr1
>select \* from usr where age=10;

(2) 向表 usr1 中插入来自 usr 表的数据并追加在原有数据后。

hive>insert into table usr1

> select \* from usr where age=10;

# 8.4 Hive 应用实例: WordCount

现在通过一个实例——词频统计,来深入学习一下 Hive 的具体使用。首先需要创建一个需要分析的输入数据文件;然后编写 HiveQL 语句实现 WordCount 算法,在 Linux 下实现步骤如下。

(1) 创建 input 目录,其中 input 为输入目录,命令如下:

```
$cd /usr/local/hadoop
$mkdir input
```

(2) 在 input 文件夹中创建两个测试文件 file1. txt 和 file2. txt,命令如下:

```
$cd /usr/local/hadoop/input
$echo "hello world">file1.txt
$echo "hello hadoop">file2.txt
```

(3) 进入 hive 命令行界面,编写 HiveQL 语句实现 WordCount 算法,命令如下:

执行完成后,用 select 语句查看运行结果,如图 8-1 所示。

```
OK
Time taken: 2.662 seconds
hive> select * from word_count;
OK
hadoop 1
hello 2
world 1
Time taken: 0.043 seconds, Fetched: 3 row(s)
```

图 8-1 WordCount 算法统计结果查询

# 8.5 Hive 编程的优势

词频统计算法是最能体现 MapReduce 思想的算法之一,因此,这里以 WordCount 实例为例,简单比较一下其在 MapReduce 中的编程实现和在 Hive 中编程实现的不同点。首先, 采用 Hive 实现 WordCount 算法需要编写较少的代码量。在 MapReduce 中, WordCount

类由 63 行 Java 代码编写而成(该代码可以通过下载 Hadoop 源码后,在以下目录: % HADOOP\_HOME/share/hadoop/mapreduce/hadoop-mapreduce-examples-2.7.1. jar 包中找到),而在 Hive 中只需要编写 7 行代码;其次,在 MapReduce 的实现中,需要进行编译生成 jar 文件来执行算法,而在 Hive 中则不需要,虽然 HiveQL 语句的最终实现需要转换为 MapReduce 任务来执行,但是这些都是由 Hive 框架自动完成的,用户不需要了解具体实现细节。

由上可知,采用 Hive 实现最大的优势是,对于非程序员,不用学习编写复杂的 Java MapReduce 代码了,只需要用户学习使用简单的 HiveQL 就可以了,而这对于有 SQL 基础的用户而言是非常容易的。

# 8.6 本章小结

Hive 是一个构建于 Hadoop 顶层的数据仓库工具,主要用于对存储在 Hadoop 文件中的数据集进行数据整理、特殊查询和分析处理。Hive 在某种程度上可以看作是用户编程接口,本身不存储和处理数据,依赖 HDFS 存储数据,依赖 MapReduce 处理数据。

本章介绍了 Hive 的安装方法,包括下载安装文件、配置环境变量、修改配置文件、安装并配置 MySQL 等。Hive 支持关系数据库中的大多数基本数据类型,同时 Hive 还支持关系数据库中不常出现的 3 种集合数据类型。Hive 提供了类似 SQL 的语句——HiveQL,可以很方便地对 Hive 进行操作,包括创建、修改、删除数据库、表、视图等。Hive 的一大突出优点是,可以把查询语句自动转化成相应的 MapReduce 任务去执行得到结果,这样就可以大大节省用户的编程工作量,本章最后通过一个 WordCount 应用实例,充分展示了 Hive 的这一优点。

# Spark 的安装和基础编程

Spark 最初诞生于美国加州大学伯克利分校的 AMP 实验室,是一个可应用于大规模数据处理的分布式计算框架,如今是 Apache 软件基金会下的顶级开源项目之一。Spark 可以独立安装使用,也可以和 Hadoop 一起安装使用。本书采用和 Hadoop 一起安装使用,这样,就可以让 Spark 使用 HDFS 存取数据。

本章首先介绍 Spark 的安装方法;然后介绍如何使用 Spark Shell 编写运行代码;最后介绍如何使用 Scala 语言和 Java 语言编写 Spark 独立应用程序。

# 9.1 基础环境

本书采用如下环境配置。

- (1) Linux 系统: Ubuntu 16.04。
- (2) Hadoop: 2.7.1 版本。
- (3) JDK: 1.7以上。
- (4) Spark: 1.6.2 版本。

请参照第2章完成 Linux 系统的安装,参照第3章完成 Hadoop 和 JDK 的安装。

Spark 目前已经更新到 2.0 以上版本,但是,在 Spark 2.0 以上版本中,一些功能组件比如 Structured Streaming 还不是正式版,因此,建议初学者学习比较成熟的 Spark 1.6.2 版本,本书采用 1.6.2 版本。

# 9.2 安装 Spark

Spark 的部署模式主要有 4 种: Local 模式(单机模式)、Standalone 模式(使用 Spark 自带的简单集群管理器)、YARN 模式(使用 YARN 作为集群管理器)和 Mesos 模式(使用 Mesos 作为集群管理器)。这里介绍 Local 模式(单机模式)的 Spark 安装。

# 9.2.1 下载安装文件

登录 Linux 系统(本书统一采用 hadoop 用户登录),打开浏览器,访问 Spark 官网 (http://spark.apache.org/downloads.html)(见图 9-1),选择 1.6.2 版本。

关于 Spark 官网下载页面中的 Choose a package type,这里补充说明如下。

(1) Source code: Spark 源码,需要编译才能使用。

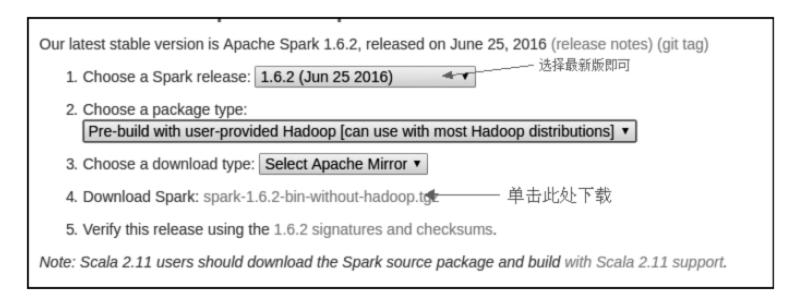


图 9-1 Spark 官网下载页面

- (2) Pre-build with user-provided Hadoop:属于 Hadoop free 版,可应用到任意 Hadoop版本。
- (3) Pre-build for Hadoop 2.6 and later:基于 Hadoop 2.6 的预先编译版,需要与本机 安装的 Hadoop 版本对应,可选的还有 Hadoop 2.6、Hadoop 2.4、Hadoop 2.3、Hadoop 1.x、CDH4。

由于我们已经自己安装了 Hadoop,所以,在 Choose a package type 后面需要选择 Prebuild with user-provided Hadoop [can use with most Hadoop distributions],然后单击 Download Spark 后面的 spark-1.6.2-bin-without-hadoop.tgz 下载即可。下载的文件,默认会被浏览器保存在"/home/hadoop/下载"目录下。

除了到 Spark 官网下载安装文件,也可以直接到本书官网的"下载专区"中下载 Spark 安装文件,单击进入下载专区后,在"软件"这个文件夹中,找到文件 spark-1. 6. 2-bin-without-hadoop. tgz,下载到本地,保存到 Linux 系统的"/home/hadoop/下载"目录下。

下载完安装文件以后,需要对文件进行解压。按照 Linux 系统使用的默认规范,用户安装的软件一般都是存放在/usr/local/目录下。使用 hadoop 用户登录 Linux 系统,打开一个终端,执行如下命令:

```
$sudo tar - zxf ~/下载/spark-1.6.2-bin-without-hadoop.tgz - C /usr/local/
$cd /usr/local
$sudo mv ./spark-1.6.2-bin-without-hadoop/ ./spark
$sudo chown - R hadoop:hadoop ./spark #hadoop 是当前登录 Linux 系统的用户名
```

# 9.2.2 配置相关文件

安装文件解压缩以后,还需要修改 Spark 的配置文件 spark-env. sh。首先可以复制一份由 Spark 安装文件自带的配置文件模板,命令如下:

```
$cd /usr/local/spark
$cp ./conf/spark-env.sh.template ./conf/spark-env.sh
```

然后使用 vim 编辑器打开 spark-env. sh 文件进行编辑,在该文件的第一行添加以下配置信息:

export SPARK DIST CLASSPATH= \$ (/usr/local/hadoop/bin/hadoop classpath)

有了上面的配置信息以后,Spark 就可以把数据存储到 Hadoop 分布式文件系统 HDFS中,也可以从 HDFS中读取数据。如果没有配置上面的信息,Spark 就只能读写本地数据,无法读写 HDFS中的数据。

配置完成后就可以直接使用 Spark,不需要像 Hadoop 那样运行启动命令。通过运行 Spark 自带的实例,可以验证 Spark 是否安装成功,命令如下:

```
$cd /usr/local/spark
$bin/run-example SparkPi
```

执行时会输出很多屏幕信息,不容易找到最终的输出结果,为了从大量的输出信息中快速找到我们想要的执行结果,可以通过 grep 命令进行过滤:

```
$bin/run-example SparkPi 2>&1 | grep "Pi is roughly"
```

上面命令涉及 Linux Shell 中关于管道的知识,可以查看网络资料学习管道命令的用法,这里不再赘述。过滤后的运行结果如图 9-2 所示,可以得到  $\pi$  的 5 位小数近似值。

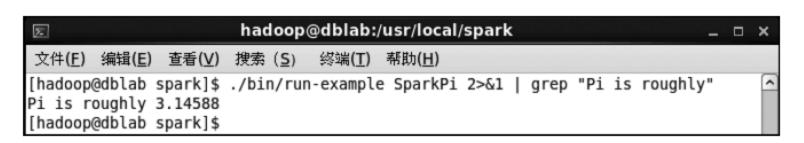


图 9-2 SparkPi 程序运行结果

# 9.3 使用 Spark Shell 编写代码

学习 Spark 程序开发,建议首先通过 Spark Shell 进行交互式编程,加深 Spark 程序开发的理解。Spark Shell 提供了简单的方式来学习 API,并且提供了交互的方式来分析数据。可以输入一条语句,Spark Shell 会立即执行语句并返回结果,这就是人们所说的交互式解释器(Read-Eval-Print Loop,REPL),它为我们提供了交互式执行环境,表达式计算完成就会输出结果,而不必等到整个程序运行完毕,因此可即时查看中间结果,并对程序进行修改,这样可以在很大程度上提升开发效率。Spark Shell 支持 Scala 和 Python,这里使用 Scala 来进行介绍。Scala 是一门现代的多范式编程语言,旨在以简练、优雅及类型安全的方式来表达常用编程模式,它平滑地集成了面向对象和函数语言的特性,运行在 JVM(Java 虚拟机)上,并兼容现有的 Java 程序。

# 9.3.1 启动 Spark Shell

可以通过下面命令启动 Spark Shell 环境:

```
$cd /usr/local/spark
```

\$./bin/spark-shell

启动 spark-shell 后,就会进入 scala>命令提示符状态,如图 9-3 所示。

图 9-3 Spark Shell 模式

现在就可以在里面输入 Scala 代码进行调试了。例如,下面在 Scala 命令提示符 scala > 后面输入一个表达式 8 \* 2+5,然后按 Enter 键,就会立即得到结果:

```
scala>8 * 2+5
res0: Int=21
```

最后可以使用命令":quit"退出 Spark Shell,如下所示:

```
scala>:quit
```

或者,也可以直接使用 Ctrl+D 键,退出 Spark Shell。

# 9.3.2 读取文件

#### 1. 读取本地文件

打开一个 Linux 终端,在终端中输入以下命令启动 Spark Shell:

```
$cd /usr/local/spark
$./bin/spark-shell
```

启动成功后,就进入了 scala>命令提示符状态,我们称这个窗口为"Spark Shell 窗口"。 现在开始读取 Linux 本地文件系统中的文件/usr/local/spark/README. md,并显示 第一行的内容,命令如下:

```
scala>val textFile=sc.textFile("file:///usr/local/spark/README.md")
scala>textFile.first()
```

执行上面语句后,就可以看到 Linux 本地文件系统的 README. md 的第一行内容了,即 # Apache Spark。

## 2. 读取 HDFS 文件

前面已经安装了 Hadoop 和 Spark,如果 Spark 不使用 HDFS,那么就不用启动 Hadoop 也可以正常使用 Spark。如果在使用 Spark 的过程中需要用到 HDFS,就要首先启动 Hadoop。因此,在 Spark 读取 HDFS 文件之前,需要首先启动 Hadoop,请新建一个 Linux 终端,执行如下命令:

\$cd /usr/local/hadoop
\$./sbin/start-dfs.sh

现在可以把本地文件/usr/local/spark/README. md 上传到 HDFS 的/user/hadoop目录下,命令如下:

\$cd /usr/local/hadoop
\$./bin/hdfs dfs - put /usr/local/spark/README.md .

上传成功以后,可以使用 cat 命令输出 HDFS 中的 README. md 中的内容,命令如下:

\$./bin/hdfs dfs - cat README.md

可以看到,该命令执行以后,屏幕上会显示整个 README. md 的内容。

现在请切换回到之前已经打开的 Spark Shell 窗口,编写语句从 HDFS 中加载 README. md 文件,并显示第一行文本内容:

scala> val textFile= sc.textFile("hdfs://localhost:9000/user/hadoop/README.md")
scala> textFile.first()

执行上面语句后,就可以看到 HDFS 文件系统中(不是本地文件系统)的 README. md 的第一行内容了,即#Apache Spark。

需要注意的是,sc. textFile("hdfs://localhost:9000/user/hadoop/README. md")中,hdfs://localhost:9000/是前面第3章介绍 Hadoop 安装内容时确定下来的端口地址 9000。实际上,也可以省略不写,如下3条语句都是等价的:

scala>val textFile=sc.textFile("hdfs://localhost:9000/user/hadoop/ README.md")
scala>val textFile=sc.textFile("/user/hadoop/ README.md")
scala>val textFile=sc.textFile("README.md")

# 9.3.3 编写词频统计程序

在第7章中曾经介绍过使用 MapReduce 编写词频统计程序的方法,实际上,Spark 可以更加快捷高效地完成词频统计功能。这里介绍如何对本地文件/usr/local/spark/README. md 进行词频统计,针对 HDFS 文件的词频统计也是类似的。

前面已经打开了多个 Linux 终端,现在切换回到 Spark Shell 窗口,在 scala>命令提示符后面输入以下代码:

```
scala>val textFile=sc.textFile("file:///usr/local/spark/ README.md")
scala> val wordCount = textFile.flatMap(line = > line.split("")).map(word = > (word, 1)).
reduceByKey((a, b) = > a + b)
scala> wordCount.collect()
```

下面简单解释一下上面的语句。textFile 包含多行文本内容,textFile.flatMap(line=>line.split(""))会遍历 textFile 中的每行文本内容,当遍历到其中一行文本内容时,会把文本内容赋值给变量 line,并执行 Lamda 表达式 line=>line.split("")。line=>line.split("")是一个 Lamda 表达式,左边表示输入参数,右边表示函数里面执行的处理逻辑,这里执行 line.split(""),也就是针对 line 中的一行文本内容,采用空格作为分隔符进行单词切分,从一行文本切分得到很多个单词构成的单词集合。这样,对于 textFile 中的每行文本,都会使用 Lamda 表达式得到一个单词集合,最终,对多行文本使用 Lamda 表达式,就得到多个单词集合。textFile.flatMap()操作就把这多个单词集合"拍扁"得到一个大的单词集合。

然后针对大的单词集合,执行 map()操作,也就是 map(word=>(word,1)),map 操作会遍历这个集合中的每个单词,当遍历到其中一个单词时,就把当前这个单词赋值给变量 word,并执行 Lamda 表达式 word=>(word,1),这个 Lamda 表达式的含义是,word 作为函数的输入参数,然后执行函数处理逻辑,这里会执行(word,1),也就是针对输入的 word,构建得到一个映射(即 Map,是一种数据结构),这个映射的 key 是 word,value 是 1(表示该单词出现一次)。

程序执行到这里,已经得到一个映射(Map),这个映射中包含了很多个(key,value)。最后,针对这个映射,执行 reduceByKey((a, b)=>a+b)操作,这个操作会把映射中的所有(key,value)按照 key 进行分组,然后使用给定的函数(这里就是 Lamda 表达式: (a,b)=>a+b),对具有相同的 key 的多个 value 进行聚合操作,返回聚合后的(key,value)。例如("hadoop",1)和("hadoop",1),具有相同的 key,进行聚合以后就得到("hadoop",2),这样就计算得到了这个单词的词频。

# 9.4 编写 Spark 独立应用程序

这里通过一个简单的应用程序 SimpleApp 来演示如何通过 Spark API 编写一个独立应用程序。使用 Scala 语言编写的程序需要使用 sbt 进行编译打包;相应地,使用 Java 语言编写的 Spark 程序需要使用 Maven 进行编译打包;而使用 Python 语言编写的 Spark 程序则可以通过 spark-submit 直接提交。

# 9.4.1 用 Scala 语言编写 Spark 独立应用程序

### 1. 安装 sbt

使用 Scala 语言编写的 Spark 程序,需要使用 sbt 进行编译打包。Spark 中没有自带 sbt,需要单独安装。可以到下面地址下载 sbt 安装文件:

https://repo.typesafe.com/typesafe/ivy-releases/org.scala-sbt/sbt-launch/0.13.11/sbt-launch.jar

或者也可以到本书官网的"下载专区"下载 sbt 安装文件,单击进入下载专区后,在"软件"这个文件夹中,找到文件 sbt-launch. jar,下载到本地,保存到 Linux 系统的"/home/hadoop/下载"目录下。

这里我们把 sbt 安装到/usr/local/sbt 目录下,使用 hadoop 用户登录 Linux 系统,新建一个终端,在终端中执行如下命令:

\$sudo mkdir /usr/local/sbt

\$sudo chown-R hadoop /usr/local/sbt

#此处的 hadoop 是 Linux 系统当前登录用户名

\$cd /usr/local/sbt

\$cp ~/下载/sbt-launch.jar.

接下来使用 vim 编辑器在/usr/local/sbt 中创建 sbt 脚本,命令如下:

\$vim ./sbt

在 sbt 脚本文件中,添加如下内容:

#!/bin/bash

SBT OPTS= "-Xms512M -Xmx1536M -Xss1M - XX:+CMSClassUnloadingEnabled -XX:

MaxPermSize=256M"

java \$SBT OPTS-jar 'dirname \$0'/sbt-launch.jar "\$@"

保存 sbt 脚本文件后退出 vim 编辑器。然后为 sbt 脚本文件增加可执行权限,命令如下:

\$chmod u+x ./sbt

最后运行如下命令,检验 sbt 是否可用:

\$./sbt sbt-version

确保计算机处于联网状态,首次运行该命令,会长时间处于"Getting org. scala-sbt sbt 0.13.11···"的下载状态,要耐心等待。如果长时间(比如半个小时)没有进度,可能是网络问

题导致安装失败,需要重新安装。安装成功以后,应该会显示类似图 9-4 所示的信息。

图 9-4 sbt 安装成功后的信息

#### 2. 编写 Scala 应用程序代码

在终端中执行如下命令创建一个文件夹 sparkapp 作为应用程序根目录:

```
$cd~ #进入用户主文件夹
$mkdir./sparkapp #创建应用程序根目录
$mkdir-p./sparkapp/src/main/scala #创建所需的文件夹结构
```

需要注意的是,为了能够使用 sbt 对 Scala 应用程序进行编译打包,需要把应用程序代码存放在应用程序根目录下的 src/main/scala 目录下。下面使用 vim 编辑器在~/sparkapp/src/main/scala 下建立一个名为 SimpleApp. scala 的 Scala 代码文件,命令如下:

```
$cd ~
$vim ./sparkapp/src/main/scala/SimpleApp.scala
```

然后在 SimpleApp. scala 代码文件中输入以下代码:

```
/* SimpleApp.scala */
import org.apache.spark.SparkContext
import org.apache.spark.SparkContext._
import org.apache.spark.SparkConf

object SimpleApp {
    def main(args: Array[String]) {
        val logFile = "file:///usr/local/spark/README.md" //Should be some file in
        your system
        val conf= new SparkConf().setAppName("Simple Application")
        val sc= new SparkContext(conf)
        val logData= sc.textFile(logFile, 2).cache()
        valnumAs= logData.filter(line=>line.contains("a")).count()
        val numBs= logData.filter(line=>line.contains("b")).count()
        println("Lines with a: %s, Lines with b: %s".format(numAs, numBs))
    }
}
```

上述代码也可以直接到本书官网"下载专区"下载,位于"代码"目录的"第9章"子目录

下,文件名是 SimpleApp. scala。这段代码的功能是,计算/usr/local/spark/README 文件中包含"a"的行数和包含"b"的行数。不同于 Spark Shell,独立应用程序需要通过 val sc=new SparkContext(conf)初始化 SparkContext。

#### 3. 用 sbt 打包 Scala 应用程序

SimpleApp. scala 程序依赖于 Spark API,因此,需要通过 sbt 进行编译打包。首先需要使用 vim 编辑器在~/sparkapp 目录下新建文件 simple. sbt,命令如下:

```
$cd ~
$vim ./sparkapp/simple.sbt
```

simple. sbt 文件用于声明该独立应用程序的信息以及与 Spark 的依赖关系,需要在 simple. sbt 文件中输入以下内容:

```
name := "Simple Project"
version := "1.0"
scalaVersion := "2.10.5"
libraryDependencies+= "org.apache.spark" %%"spark-core" %"1.6.2"
```

上述代码也可以直接到本书官网"下载专区"下载,位于"代码"目录的"第9章"子目录下,文件名是 simple. sbt。

为了保证 sbt 能够正常运行, 先执行如下命令检查整个应用程序的文件结构:

```
$cd ~/sparkapp
$find.
```

文件结构应该是类似如下所示的内容:

```
.
./src
./src/main
./src/main/scala
./src/main/scala/SimpleApp.scala
./simple.sbt
```

接下来可以通过如下代码将整个应用程序打包成 JAR(首次运行时, sbt 会自动下载相关的依赖包):

```
$cd ~/sparkapp #一定把这个目录设置为当前目录
$/usr/local/sbt/sbt package
```

对于刚刚安装的 Spark 和 sbt 而言,第一次执行上面命令时,系统会自动从网络上下载各种相关的文件,因此上面执行过程需要消耗几分钟,后面如果再次执行 sbt package 命令,

速度就会快很多,因为不再需要下载相关文件。执行上述命令后,屏幕上会返回如下类似信息:

```
OpenJDK 64-Bit Server VM warning: ignoring option MaxPermSize=256M; support was removed in 8.0
```

[info] Set current project to Simple Project (in build file:/home/hadoop/sparkapp/)

[info] Updating {file: /home/hadoop/sparkapp/}SimpleApp...

[info] Resolving org.fusesource.jansi#jansi;1.4 ...

[info] downloading https://repol.maven.org/maven2/org/apache/avro/avro/1.7.7/avro-1.7.7. jar •••

[info] [SUCCESSFUL] org.apache.avro#avro;1.7.7!avro.jar (118465ms)

[info] Done updating.

[info] Compiling 1 Scala source to /home/hadoop/sparkapp/target/scala-2.10/classes...

[info] Packaging /home/hadoop/sparkapp/target/scala-2.10/simple-project\_2.10-1.0.jar ···

[info] Done packaging. //注意,屏幕上返回这条信息表示打包成功

[success] Total time: 158 s, completed 2017-1-31 15:25:15

生成的 JAR 包的位置为~/sparkapp/target/scala-2.10/simple-project\_2.10-1.0.jar。

## 4. 通过 spark-submit 运行程序

可以将生成的 JAR 包通过 spark-submit 提交到 Spark 中运行,命令如下:

```
$/usr/local/spark/bin/spark-submit --class "SimpleApp" ~/sparkapp/target/
scala-2.10/simple-project 2.10-1.0.jar
```

上面命令执行后会输出太多信息,可以不使用上面命令,而使用下面命令运行程序,这样就可以直接得到想要的结果:

```
$/usr/local/spark/bin/spark-submit --class "SimpleApp" ~/sparkapp/target/scala-2.10/simple-project 2.10-1.0.jar 2>&1 | grep "Lines with a:"
```

最终得到的结果如下:

```
Lines with a: 58, Lines with b: 26
```

# 9.4.2 用 Java 语言编写 Spark 独立应用程序

#### 1. 安装 Maven

Ubuntu 中没有自带安装 Maven,需要手动安装 Maven。可以访问 Maven 官网下载安装文件,下载地址如下:

http://apache.fayea.com/maven/maven-3/3.3.9/binaries/apache-maven-3.3.9-bin.zip

或者,也可以访问本书官网的"下载专区"进行下载,位于"软件"目录下,文件名是 apache-maven-3.3.9-bin.zip。下载到 Maven 安装文件以后,保存到"~/下载"目录下。然 后可以选择安装在/usr/local/maven 目录中,命令如下:

```
$sudo unzip ~/下载/apache-maven-3.3.9-bin.zip-d/usr/local
$cd/usr/local
$sudo mv apache-maven-3.3.9/./maven
$sudo chown - R hadoop./maven
```

#### 2. 编写 Java 应用程序代码

在 Linux 终端中执行如下命令,在用户主文件夹下创建一个文件夹 sparkapp2 作为应用程序根目录:

```
$cd ~ #进入用户主文件夹
$mkdir-p./sparkapp2/src/main/java
```

然后使用 vim 编辑器在./sparkapp2/src/main/java 目录下建立一个名为 SimpleApp. java 的文件,命令如下:

```
$vim ./sparkapp2/src/main/java/SimpleApp.java
```

在 SimpleApp. java 文件中输入如下代码:

```
/*** SimpleApp.java ***/
import org.apache.spark.api.java. *;
import org.apache.spark.api.java.function.Function;
public class SimpleApp {
    public static void main(String[] args) {
        String logFile="file:///usr/local/spark/README.md"; //Should be some
        file in your system
        JavaSparkContext sc=new JavaSparkContext ("local", "Simple App",
             "file:///usr/local/spark/", new String[]{"target/simple-project
             -1.0.jar"});
        JavaRDD< String> logData= sc.textFile (logFile) .cache();
        long numAs=logData.filter(new Function<String, Boolean>() {
            public Boolean call(String s) { return s.contains("a"); }
        }).count();
        long numBs=logData.filter(new Function<String, Boolean>() {
            public Boolean call(String s) { return s.contains("b"); }
```

```
}).count();
System.out.println("Lines with a: "+numAs+", lines with b: "+numBs);
}
```

上述代码也可以直接到本书官网"下载专区"下载,位于"代码"目录的"第9章"子目录下,文件名是 SimpleApp. java。

该程序依赖 Spark Java API,因此,我们需要通过 Maven 进行编译打包。需要使用 vim 编辑器在~/sparkapp2 目录中新建文件 pom. xml,命令如下:

```
$cd ~
$vim ./sparkapp2/pom.xml
```

然后在 pom. xml 文件中添加如下内容,用来声明该独立应用程序的信息以及与 Spark 的依赖关系:

```
ct>
   <groupId>edu.berkeley/groupId>
   <artifactId> simple- project< /artifactId>
   <modelVersion> 4.0.0/modelVersion>
   <name>Simple Project
   <packaging> jar</packaging>
   <version> 1.0
   < repositories>
       <repository>
           <id>Akka repository</id>
           <url>http://repo.akka.io/releases</url>
       </repository>
   </repositories>
   <dependencies>
       <dependency><!--Spark dependency -->
           <groupId>org.apache.spark/groupId>
           <artifactId>spark-core 2.10</artifactId>
           <version>1.6.2/version>
       </dependency>
   </dependencies>
</project>
```

该文件也可以直接到本书官网"下载专区"下载,位于"代码"目录的"第9章"子目录下, 文件名是 pom. xml。

#### 3. 使用 Maven 打包 Java 程序

为了保证 Maven 能够正常运行, 先执行如下命令来检查整个应用程序的文件结构:

```
$cd ~/sparkapp2
$find
```

文件结构应该是类似如下的内容:

```
.
./pom.xml
./src
./src/main
./src/main/java
./src/main/java
```

接下来可以通过如下代码将整个应用程序打包成 JAR 包(注意: 计算机需要保持连接 网络的状态,而且首次运行打包命令时, Maven 会自动下载依赖包,需要消耗几分钟的时间):

```
$cd ~/sparkapp2 #一定把这个目录设置为当前目录
$/usr/local/maven/bin/mvn package
```

如果屏幕返回如下信息,则说明生成 JAR 包成功:

```
[INFO] Building jar: /home/hadoop/sparkapp2/target/simple-project-1.0.jar
[INFO]------
[INFO] BUILD SUCCESS
[INFO]------
[INFO] Total time: 4.665 s
[INFO] Finished at: 2017-01-31T 15:57:09+08:00
[INFO] Final Memory: 30M/72M
[INFO]------
```

## 4. 通过 spark-submit 运行程序

最后可以将生成的 JAR 包通过 spark-submit 提交到 Spark 中运行,命令如下:

```
$/usr/local/spark/bin/spark-submit --class "SimpleApp" ~/sparkapp2/target/
simple-project-1.0.jar
```

上面命令执行后会输出太多信息,可以不使用上面命令,而使用下面命令运行程序,这样就可以直接得到想要的结果:

```
$/usr/local/spark/bin/spark-submit --class "SimpleApp" ~/sparkapp2/target/
simple-project-1.0.jar 2>&1 | grep "Lines with a"
```

最终得到的结果如下:

Lines with a: 58, Lines with b: 26

# 9.5 本章小结

Spark 是基于内存的分布式计算框架,减少了迭代计算时的 I/O 开销。虽然 Hadoop 已成为大数据的事实标准,但是 MapReduce 分布式计算模型仍存在诸多缺陷,而 Spark 不仅具备了 Hadoop MapReduce 的优点,而且解决了 Hadoop MapReduce 的缺陷。Spark 正以其结构一体化、功能多元化的优势逐渐成为当今大数据领域最热门的大数据计算平台。

本章详细介绍 Spark 的安装配置方法,并且把 Spark 配置为和 Hadoop 一起使用,可以让 Spark 访问 HDFS 中的数据。

Spark Shell 提供了简单的方式来学习 API,并且提供了交互的方式来分析数据。本章详细介绍如何启动 Spark Shell、读取文件,以及如何编写词频统计程序。

可以使用 Spark API 编写独立应用程序。使用 Scala 语言编写的程序需要使用 sbt 进行编译打包,相应地,使用 Java 语言编写的 Spark 程序需要使用 Maven 进行编译打包。本章最后分别介绍如何使用 Scala 和 Java 两种语言编译运行 Spark 独立应用程序。

# 第 10 章

# 典型的可视化工具的使用方法

数据可视化是大数据分析的最后环节,也是非常关键的一环。在大数据时代,数据容量和复杂性的不断增加,限制了普通用户从大数据中直接获取知识,可视化的需求越来越大,依靠可视化手段进行数据分析必将成为大数据分析流程的主要环节之一。让"茫茫数据"以可视化的方式呈现,让枯燥的数据以简单友好的图表形式展现出来,可以让数据变得更加通俗易懂,有助于用户更加方便快捷地理解数据的深层次含义,有效参与复杂的数据分析过程,提升数据分析效率,改善数据分析效果。

本章分别介绍了 5 种典型的可视化工具的使用方法,包括 Easel.ly、D3、Tableau、魔镜、ECharts 等。

# 10.1 Easel. ly 信息图制作方法

本节介绍信息图的概念,并给出使用 Easel. ly 制作信息图的方法。

# 10.1.1 信息图

信息图是指数据、信息或知识的可视化表现形式。信息图主要用于清楚准确地解释或表达甚为复杂且大量的信息。图 10-1 是一个典型的信息图,显示的是全球各大洲的石油消费情况,效果一目了然。

# 10.1.2 信息图制作基本步骤

Easel. ly 是非常流行的信息图制作软件之一,具有界面简洁、操作简便、图片精美等特点。用户只需要登录 Easel. ly 官方网站(http://www.easel. ly/),即可进行信息图制作。可以在 Windows 或 Linux 系统中打开浏览器进行可视化图表制作,但是,建议在 Windows 系统下操作,使用起来会更加顺畅。建议在 Windows 系统中打开浏览器登录 Easel. ly 官网制作信息图。

#### 1. 选择模板

进入 Easel. ly 页面后,就可以开始创建信息图。如图 10-2 所示,可以选择两种方法创建信息图。

(1) 创建空白模板。

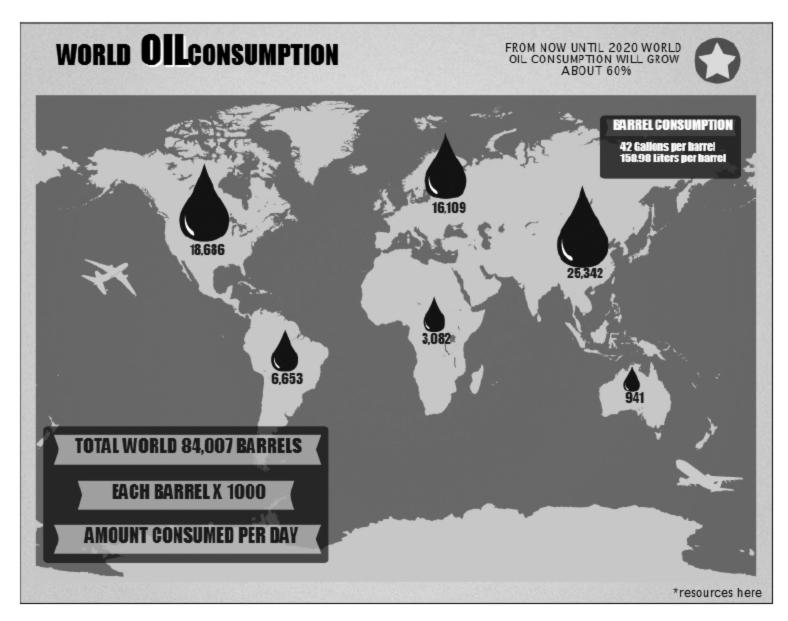


图 10-1 一个信息图实例

(2)选择一个已有模板,在其基础上进行制作,模板内的内容可以修改。目前 Easel. ly 官网上已经有超过 200 万的模板,且可以通过选项进行筛选。推荐使用模板进行制作。

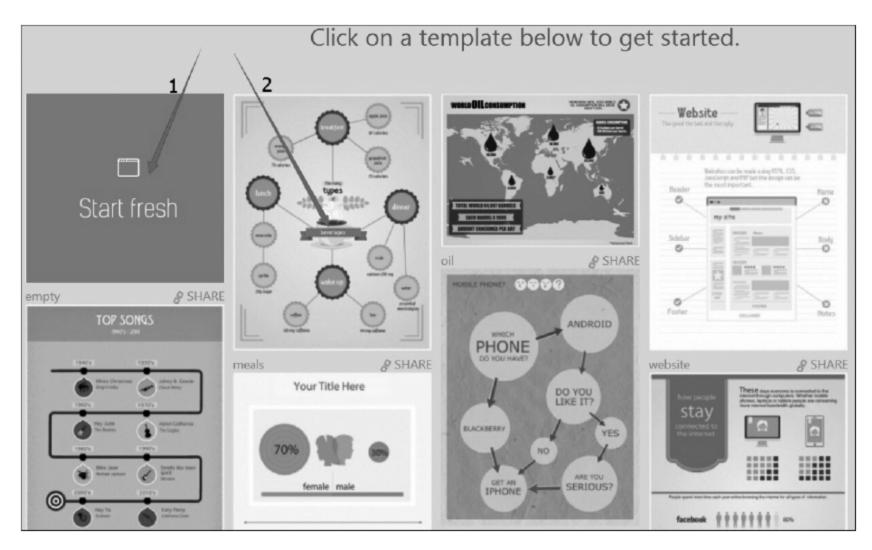


图 10-2 Easel.ly页面

## 2. 编辑内容

选好模板后,就可以开始进行信息图的制作。图 10-3 展示的是 Easel. ly 的工具栏,显示了 Easel. ly 的所有功能。

图 10-3 中,从左到右的功能依次如下。



图 10-3 Easel. ly 工具栏

- (1) Vhemes: 模板选择。
- (2) Objects: 添加元素。
- (3) backgrounds: 选择背景。
- (4) shapes: 添加线条。
- (5) text: 添加文本。
- (6) charts: 添加数据图表,可选直方图、曲线图、卫星图、雷达图、饼状图。
- (7) upload: 上传图片。

首先需要在 backgrounds 中选择一个背景,并选择需要的尺寸,然后拖动你需要的背景到下方的工作面板上即可,效果如图 10-4 所示。

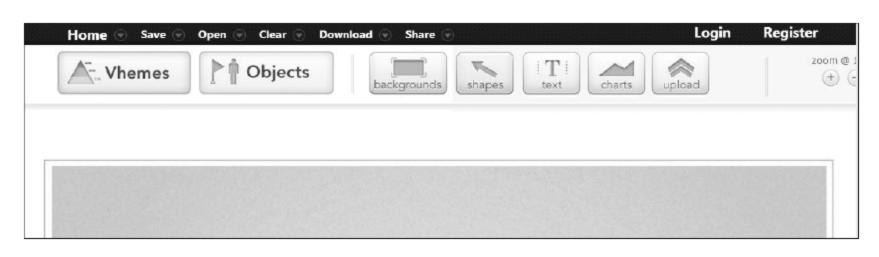


图 10-4 工作面板

现在就可以陆续向这个面板上添加各种元素,完成所要的信息图。只要将工具栏中的元素拖到需要添加的地方,就能完成元素的添加,过程十分简便。例如,在工具栏的 charts 中拖动曲线图的图标到面板上,调整尺寸、添加数据后,就能完成添加一个数据图的操作。在工具栏的 text 选项下拖动 Title 模块,输入标题名称并添加适当的 banners 即可完成标题的添加。

Easel. ly 提供了很多其他可供添加的元素,使得制作出来的信息图十分精美。当单击操作台中的 Objects 时,就可以进行元素的选择和添加,如图 10-5 所示。

Easel. ly 提供了元素的检索功能,当需要进行添加时,只需要找到需要的元素图像,然后拖动到面板上,再调整大小、角度,添加需要的文字即可。

## 3. 导出图片

在运用 Easel. ly 制作出信息图以后,可以进行图片的导出,步骤如下。

- (1) 单击操作台最右侧的 Present。
- (2) 右击完成的图片,在弹出的快捷菜单中选择

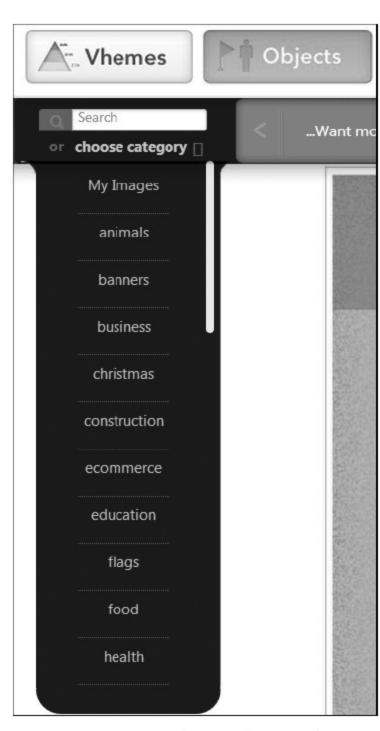


图 10-5 元素的选择和添加

"图片另存为",就可以将制作的图片保存到本地。

#### 4. 中文兼容性问题

在使用过程中,可能会碰到 Easel. ly 中文兼容问题,即导出图片时中文字体显示错乱问题,如图 10-6 所示,有些中文被加粗显示,有些中文没有加粗显示,很不美观。

这是由于 Easel. ly 网站内部的问题,目前暂无完美的解决方案,这里给出一个不完全的解决方案,仅供参考。

首先必须要登录 Easel. ly,然后在信息图制作完成后,单击顶部菜单中的 Save 选项保存,再单击 Share 选项选择 View in Browser。此时,制作好的信息图就可以在浏览器中显示,此时中文是显示正常的(见图 10-7)。最后,把浏览器中的显示效果进行截屏得到图片,或者直接把浏览器中的图片右击,在弹出的快捷菜单中选择"另存为",就可以保存成图片。但是,这种方法存在清晰度不高的问题。

这是中文你好, CA BND
这是中文你好, Comic Sans
这是中文你好, courier
这是中文你好, DejaVu
这是中文你好, Delicious
这是中文你好, Concient

图 10-6 中文乱码效果

这是中文你好,Helve 这是中文你好,Impact 这是中文你好,Lucida 这是中文你好,Monaco 这是中文你好,Myriad 这是中文你好,Myriad

图 10-7 中文正常显示效果

# 10.2 D3 可视化库的使用方法

D3 的全称是 Data-Driven Documents,顾名思义,它是一个被数据驱动的文档。实际上,D3 是一个 JavaScript 函数库,主要用来做数据可视化。这里只是简要介绍 D3 的一些最基本的使用方法,以及如何生成一些比较简单的图表。在学习本节内容时,会涉及以下概念。

- (1) HTML: 超文本标记语言,用于设定网页的内容。
- (2) CSS: 层叠样式表,用于设定网页的样式。
- (3) JavaScript: 一种直译式脚本语言,用于设定网页的行为。
- (4) DOM: 文档对象模型,用于修改文档的内容和结构。
- (5) SVG: 可缩放矢量图形,用于绘制可视化的图形。

建议通过查找网络资料加深对上述概念的理解,这里不再赘述。可以在 Windows 或 Linux 系统中打开浏览器进行可视化图表制作,建议在 Windows 系统下操作,使用起来会更加顺畅。

# 10.2.1 D3 可视化库的安装

D3 是一个 JavaScript 函数库,这里所说的"安装",并非通常意义上的安装,而只需要在 HTML 中引用一个 D3. js 文件即可。可以有两种方法引用 D3. js 文件。

- (1) 访问 D3. js 官网(https://d3js.org/),下载 D3. js 文件,解压后,在 HTML 文件中包含相关的 js 文件即可。本书官网的"下载专区"的"代码"的"第 10 章"目录下,也提供了 D3. js 文件的下载,文件名是 d3. zip。
  - (2) 直接包含网络的链接,即在 HTML 文件中写入如下代码:

```
<script src="http://d3js.org/d3.v3.min.js" charset="utf-8"></script>
```

方法(1)是把 D3. js 文件下载到本地使用,所以,在使用过程中不需要连接网络;而方法(2)则需要在使用过程中能够连接到互联网。

# 10.2.2 基本操作

#### 1. 添加元素

比如,选择 body 标签,为之添加一个 p 标签,并设置它的内容为"New paragraph!",则可以使用如下 JavaScript 语句:

```
d3.select("body").append("p").text("New paragraph!");
```

需要把这行 JavaScript 语句放入 HTML 代码中,文件名为 example1. html,代码如下:

example1. html 代码文件可以直接从本书官网"下载专区"的"代码"目录的"第 10 章"子目录下载。在上面这段 HTML 代码中,采用了直接包含网络链接的形式来引用 D3. js 文件。在浏览器中打开这个 HTML 文件,就可以看到如图 10-8 所示的效果。

New paragraph!

图 10-8 网页效果

#### 2.数据绑定

D3 可以处理哪些类型的数据呢?它可以接受几乎任何数字数组、字符串或对象(本身包含其他数组或键值对),还可以处理 JSON 和 GeoJSON。下面给出一段实例代码,文件名称为 example2. html:

```
<!DOCTYPE html>
<html>
  < head>
    <title>testD3-1.html</title>
    <script type="text/javascript" src="http://d3js.org/d3.v3.min.js">
    </script>
  < /head>
  <body>
    This is my HTML page. < br>
  </body>
  <script type="text/javascript">
  var dataset= [ 5, 10, 15, 20, 25 ];
  d3.select("body").selectAll("p")
    .data(dataset)
    .enter()
    .append("p")
    .text("New paragraph!");
 </script>
</html>
```

example2. html 代码文件可以直接从本书官网"下载专区"的"代码"目录的"第 10 章"子目录下载。上面这段代码解释如下。

- (1) d3. select("body"): 查找 DOM 中的 body。
- (2) selectAll("p"): 选择 DOM 中的所有段落。
- (3) data(dataset): 计数和分析数据值。本实例中, dataset 中有 5 个值,每个值都会执行一次。
- (4) enter(): 绑定数据和 DOM 元素。这个方法将数据传递到 DOM 中。如果数据值比相应的 DOM 元素多,就用 enter()创建一个新元素的占位符。
- (5) append("p"): 通过 enter()创建的占位符,在 DOM 中插入一个 p 元素。
- (6) text("New paragraph!"): 为新创建的 p 标签插入一个文本值。

在浏览器中打开这个 HTML 文件,就可以看到如图 10-9 所示的效果。

```
This is my HTML page.

New paragraph!

New paragraph!

New paragraph!

New paragraph!

New paragraph!
```

图 10-9 绑定数据后的网页效果

#### 3. 用层画条形图

1) 为同类层添加样式

```
div.bar {
    display: inline-block;
    width: 20px;
    height: 75px;    /* We'll override this later */
    background-color: teal;
}
```

2) 声明要为某类层设置属性

```
.attr("class", "bar")
```

3) 为每个特定的层设置属性

```
.style("height", function(d) {
    var barHeight=d * 5; //Scale up by factor of 5
    return barHeight+"px";
});
```

4) 设置层之间的间隔

```
margin-right: 2px;
```

5) 完整的源代码

下面是完整的 HTML 源代码,文件名是 example3. html:

```
background-color: teal;
            }
    </style>
    </head>
    <body>
        <script type="text/javascript">
            var dataset= [ 5, 10, 15, 20, 25 ];
            d3.select("body").selectAll("div")
                 .data(dataset)
                 .enter()
                 .append("div")
                 .attr("class", "bar")
                 .style("height", function(d) {
                     var barHeight=d * 5;
                     return barHeight+"px";
                 });
        </script>
    </body>
</html>
```

example 3. html 代码文件可以直接从本书官网"下载专区"的"代码"目录的"第 10 章"子目录下载。上述 HTML 代码,在浏览器中打开以后会显示如图 10-10 所示的效果。

## 4. 绘制 SVG 图形

#### 1) 简单形状

SVG 标签包含一些视觉元素,包括矩形、圆形、椭圆形、线条、文字和路径等。绘制 SVG 图形采用了基于像素的坐标系统,其中,浏览器的左上角是原点(0,0),x 和 y 的正方向分别是右和下。

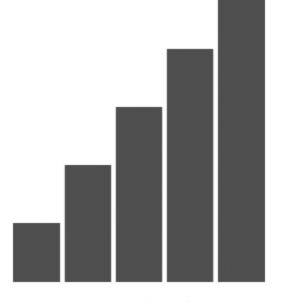


图 10-10 网页中的条形图效果

## (1) 矩形。

使用 x 和 y 指定左上角的坐标, width 和 height 指定尺寸。绘制 SVG 矩形的代码如下:

```
<rectx="0" y="0" width="500" height="50"/>
```

#### (2) 圆。

使用 cx 和 cy 指定半径的中心的坐标,使用 r 表示半径,例如:

```
<circle cx= "250" cy= "25" r= "25"/>
```

#### (3) 椭圆。

使用 cx 和 cy 指定半径的中心的坐标, rx 和 ry 分别指定 x 方向和 y 方向上圆的半径, 例如:

```
<ellipse cx="250" cy="25" rx="100" ry="25"/>
```

## (4)线。

使用 x1 和 y1 到指定线的一端的坐标,x2 和 y2 指定另一端的坐标。stroke 指定描边,使得线是可见的,例如:

```
x1="0" y1="0" x2="500" y2="50" stroke="black"/>
```

## (5) 文本。

使用 x 和 y 指定文本的位置,例如:

```
<text x= "250" y= "25"> Easy-peasy</text>
```

可以给文本设置样式,例如:

```
<text x= "250" y= "155" font- family= "sans- serif" font- size= "25" fill= "gray"> Easy- peasy
</text>
```

#### 2) 绘图样例

下面是一段绘制 SVG 图形的 HTML 源代码,文件名是 example4. html:

```
<!DOCTYPE html>
<html>
  < head>
    <meta charset="utf-8">
    <title>testD3-6-SVG.html</title>
    <script type="text/javascript" src="http://d3js.org/d3.v3.min.js">
    </script>
    <style type="text/css">
        .pumpkin {
        fill: yellow;
           stroke: orange;
               stroke-width: 5;
  </style>
  </head>
  <body>
  <script type="text/javascript"></script>
  < svg width= 500 height= 960>
```

```
< rect x="0" y="0" width="500" height="50"/>
      <ellipse cx="250" cy="225" rx="100" ry="25"/>
      x1="0" y1="120" x2="500" y2="50" stroke="black"/>
      <text x="250" y="155" font-family="sans-serif"
               font-size="25" fill="gray">Easy-peasy</text>
      <circle cx="25" cy="80" r="20"</pre>
               fill="rgba(128, 0, 128, 0.75)"
               stroke="rgba(0, 255, 0, 0.25)"
               stroke-width="100"/>
      <circle cx="75" cy="80" r="20"</pre>
               fill="rgba(0, 255, 0, 0.75)"
               stroke="rgba(0, 0, 255, 0.25)" stroke-width="10"/>
      <circle cx="125" cy="80" r="20"</pre>
               fill="rgba(255, 255, 0, 0.75)"
               stroke="rgba(255, 0, 0, 0.25)" stroke-width="10"/>
      <rect x="0" y="300" width="30" height="30" fill="purple"/>
      <rect x="20" y="305" width="30" height="30" fill="blue"/>
      <rect x="40" y="310" width="30" height="30" fill="green"/>
      <rect x="60" y="315" width="30" height="30" fill="yellow"/>
      <rect x="80" y="320" width="30" height="30" fill="red"/>
      <circle cx="25" cy="425" r="22" class="pumpkin"/>
      <circle cx="25" cy="525" r="20" fill="rgba(128, 0, 128, 1.0)"/>
      <circle cx="50" cy="525" r="20" fill="rgba(0, 0, 255, 0.75)"/>
      <circle cx= "75" cy= "525" r= "20" fill= "rgba(0, 255, 0, 0.5)"/>
      <circle cx= "100" cy= "525" r= "20" fill= "rgba (255, 255, 0, 0.25) "/>
      <circle cx="125" cy="525" r="20" fill="rgba(255, 0, 0, 0.1)"/>
      <circle cx="25" cy="625" r="20" fill="purple"</pre>
               stroke="green" stroke-width="10"
      opacity="0.9"/>
      <circle cx="65" cy="625" r="20" fill="green"</pre>
               stroke="blue" stroke-width="10"
               opacity="0.5"/>
      <circle cx="105" cy="625" r="20" fill="yellow"</pre>
               stroke="red" stroke-width="10"
           opacity="0.1"/>
  </svg>
 </body>
</html>
```

example4. html 代码文件可以直接从本书官网"下载专区"的"代码"目录的"第 10 章"子目录下载。上述 HTML 代码,在浏览器中打开以后会显示如图 10-11 所示的效果。

#### 5. 散点图

下面是给出绘制散点图的一段 HTML 代码样例,文件名是 example5. html:

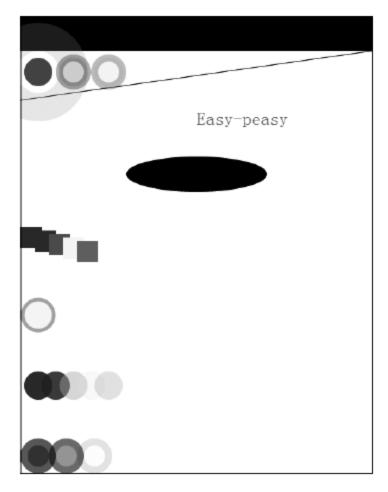


图 10-11 网页中的 SVG 图形效果

```
<!DOCTYPE html>
<html>
  < head>
    <meta charset="utf-8">
        <title>testD3-9-drawScatterLot.html</title>
        <script type="text/javascript" src="http://d3js.org/d3.v3.min.js">
        </script>
    <style type="text/css">
        </style>
    </head>
  <body>
      <script type="text/javascript">
           //width and height
           var w=600;
           var h=100;
           var dataset=[
                            [5, 20], [480, 90], [250, 50], [100, 33], [330, 95],
                            [410, 12], [475, 44], [25, 67], [85, 21], [220, 88]
                          ];
           //Create SVG element
           var svg=d3.select("body")
                        .append("svg")
                        .attr("width", w)
                        .attr("height", h);
           svg.selectAll("circle")
               .data(dataset)
               .enter()
               .append("circle")
```

```
.attr("cx", function(d) {
                    return d[0];
               })
               .attr("cy", function(d) {
                    return d[1];
               })
               .attr("r", function(d) {
                    return Math.sqrt(h-d[1]);
               });
           svg.selectAll("text")
               .data(dataset)
               .enter()
               .append("text")
               .text(function(d) {
                    return d[0]+","+d[1];
               })
               .attr("x", function(d) {
                    return d[0];
               })
               .attr("y", function(d) {
                    return d[1];
               })
               .attr("font-family", "sans-serif")
               .attr("font-size", "11px")
               .attr("fill", "red");
      </script>
</body>
</html>
```

example 5. html 代码文件可以直接从本书官网"下载专区"的"代码"目录的"第 10 章"子目录下载。上述 HTML 代码,在浏览器中打开以后会显示如图 10-12 所示的效果。

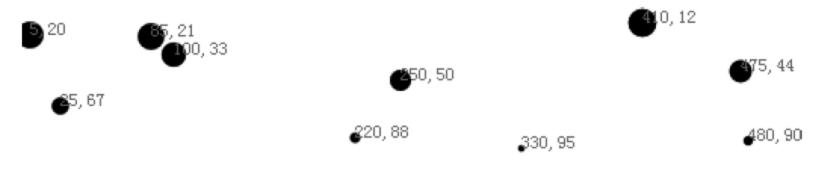


图 10-12 网页中的散点图效果

# 10.3 可视化工具 Tableau 使用方法

Tableau 是一款数据可视化工具,托放式的操作和精美的图表,让这款软件在大数据可视化方面大放光彩。Tableau 是桌面系统中最简单的商业智能工具软件,它没有强迫用户

编写自定义代码,新的控制台也可完全自定义配置。Tableau 控制台十分灵活,具有高度的动态性,在控制台上,不仅能够监测信息,而且还提供完整的分析能力。Tableau 可以将数据运算与美观的图表很好地嫁接在一起,它的程序很容易上手,用户可以用它将大量数据拖放到数字"画布"上,转眼间就能创建好各种图表。

## 10.3.1 安装 Tableau

Tableau 是一款收费软件,但是有一个免费试用期,默认是 14 天。可以访问 Tableau 官网(http://www.tableau.com/zh-cn)下载安装文件。Tableau 目前不支持 Linux 系统,建议在 Windows 系统下安装和使用 Tableau。进入官网后,单击右上角的"免费试用",然后选择桌面版,单击"开始使用"选项,然后就会出现下载的弹窗,单击"下载"按钮即可。Tableau 安装过程十分简单,只需要双击安装包,跟着提示一步一步操作即可顺利完成安装。

## 10.3.2 界面功能介绍

## 1. 首界面

启动 Tableau 软件后,首先会出现一个首界面,如图 10-13 所示。



图 10-13 Tableau 首界面

界面的左边指示数据的来源, Tableau 可以连接到本地的 Excel 表格、文本、Access 数据库和统计文件等,也可以连接数据库服务器,如 Microsoft SQL Server 数据库、MySQL 数据库和 Oracle 数据库等。界面左下角显示了已保存的数据源。界面中间上面部分显示了最近打开过的工作簿,下面部分显示示例工作簿,即 Tableau 自带的一些工作簿,可以单击更多样本查看更多的数据图。界面右边显示了探索、每周精选以及 Tableau 一些社区、博客和新闻等。第一次运行该软件,可以单击某一个示例工作簿,查看该软件数据展示的图示,以及如何简单操作。这里选择示例超市工作簿,打开之后如图 10-14 所示。



图 10-14 超市工作簿示例

这个界面是仪表板界面,由以下几个组件构成。

- (1) 仪表板:显示当前仪表板能看到的工作表,其中有打钩标志是已经添加到当前仪表板的工作表,没有打钩的是还未添加到当前仪表板的工作表。仪表板还可以添加文本、图像、空白等对象,以及设置这些对象布局方式。
  - (2) 布局:显示当前仪表板下所有工作表以及对象的层次关系。
  - (3) 属性窗口:显示当前组件的属性,如果单击仪表板,则显示仪表板的属性。
  - (4) 容器: 可以存放工作簿和各种对象的容器,是一个仪表板放置内容的地方。
- (5)智能显示:提供各种图示,当设置好行列数据之后,单击智能显示里的各种图,就可以显示当前的数据相应的图例。
- (6) 工作表和仪表板列表: 界面底部用矩形框框住的部分,单击左侧第一个按钮可以切换到数据源模式。中间部分是已经打开的仪表板和工作表列表,仪表板前面有田字格图标和工作表图标。最后3个图标表示新建工作表、仪表板和故事。

## 2. 工作表界面

工作表是针对数据源部分数据或者所有数据操作的区域,可以制作出各种各样的图表。单击"新建工作表"图标以后,会弹出如图 10-15 所示界面。

工作表界面的左侧是数据源的一些属性,其中,"维度"表示表格的文本属性,"度量"表示表格中数据属性,"集"表示数据源部分数据的集合,"参数"表示一些额外定义的参数。工

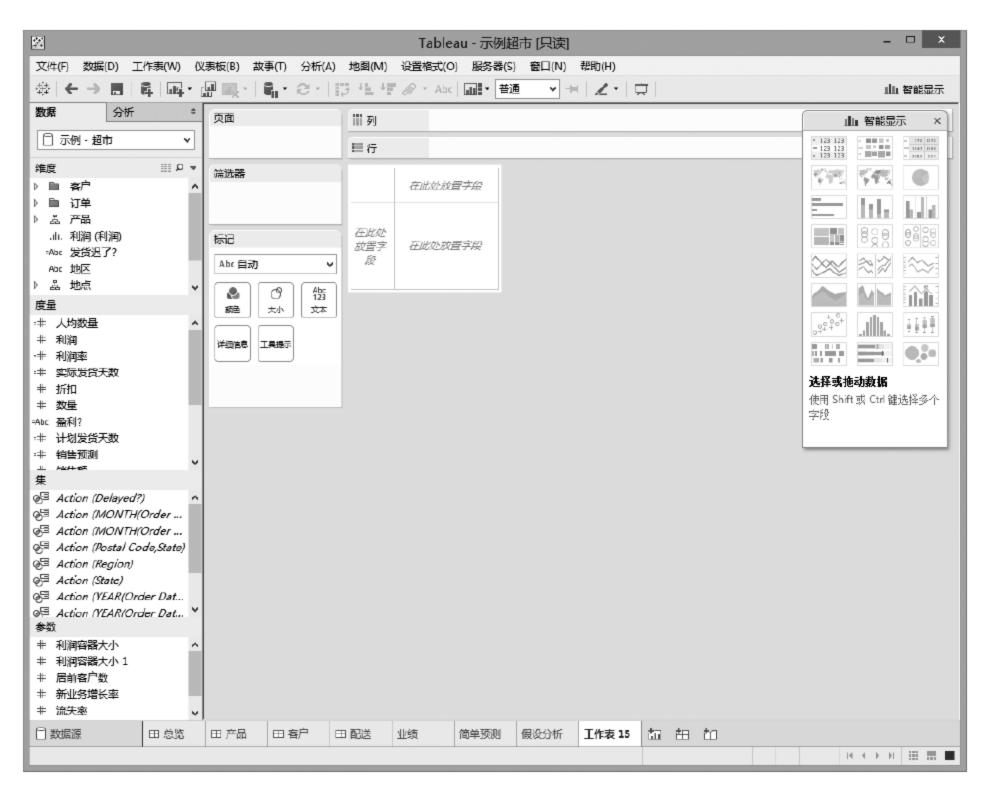


图 10-15 新建工作表界面

作表界面右侧是工作区域,可以把维度某个属性拖到"行",把度量的某个属性拖到"列",或者反过来,就可以制作这两个属性的数据图。"刷选区域"主要是针对某些属性进行数据筛选。"标记区域"主要用处是,当要用不同颜色表示不同数据时,在标记区域就会标注不同颜色对应的数据种类。

#### 3. 仪表板界面

仪表板主要是工作表和一些对象的集合(文本和网页等),如图 10-16 所示。

这是一个新建的仪表板,容器内区域还是空的。可以把左上角的工作表添加到容器空白区域,也可以把文本、图像等对象添加到容器空白区域,构成一个仪表板。

# 10.3.3 Tableau 简单操作

经过之前的简单介绍,接下来通过制作两个简单的工作表和仪表板来展示 Tableau 是如何操作的。数据是使用 Tableau 自带的超市示例数据。但是,不能像之前那样打开,否则打开的是一个 Tableau 文件,而是需要单击软件首界面(见图 10-13)左侧的"连接"下的 Excel", Tableau 默认会打开示例文件夹,单击"示例-超市"即可。然后,如图 10-17 所示,界面左侧会列出超市这个表格下的 3 个子工作表,当选中其中一个子工作表并且双击时,在界面右边区域的下部分就会显示该子工作表的数据。例如,这里双击"订单"这个子工作表,则会显示如下图所示的数据,当然,还可以单击右上角的"添加筛选器",进行数据过滤。

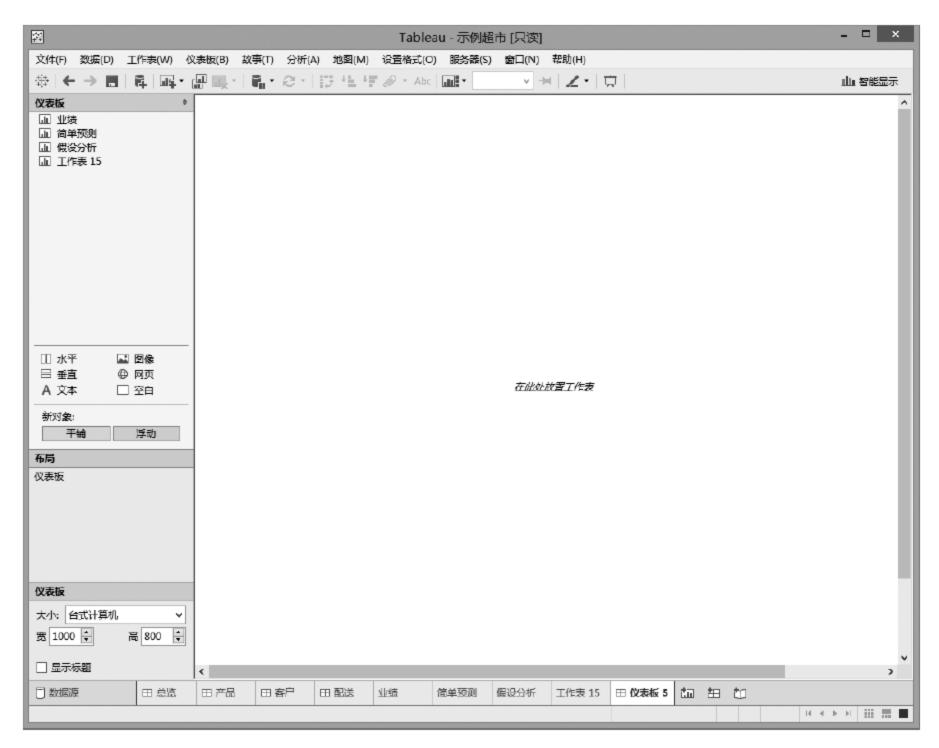


图 10-16 新建的仪表板

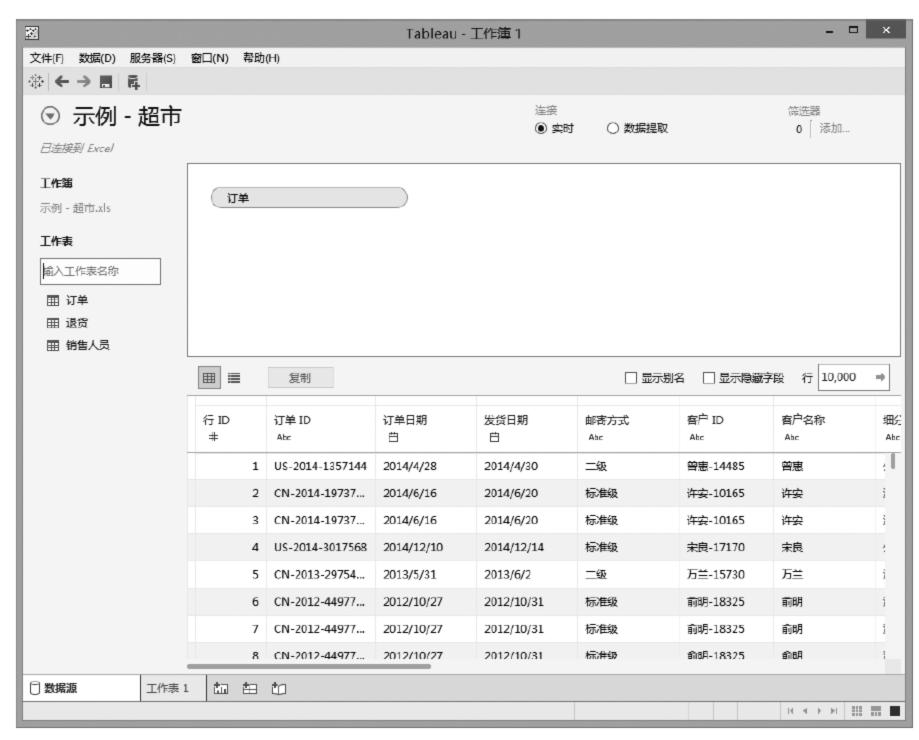


图 10-17 超市工作簿的 3 个工作表

此时,可以新建一个工作表或者直接用软件默认打开的工作表 1。此时打开的工作表就是针对订单中的数据,如图 10-18 所示。

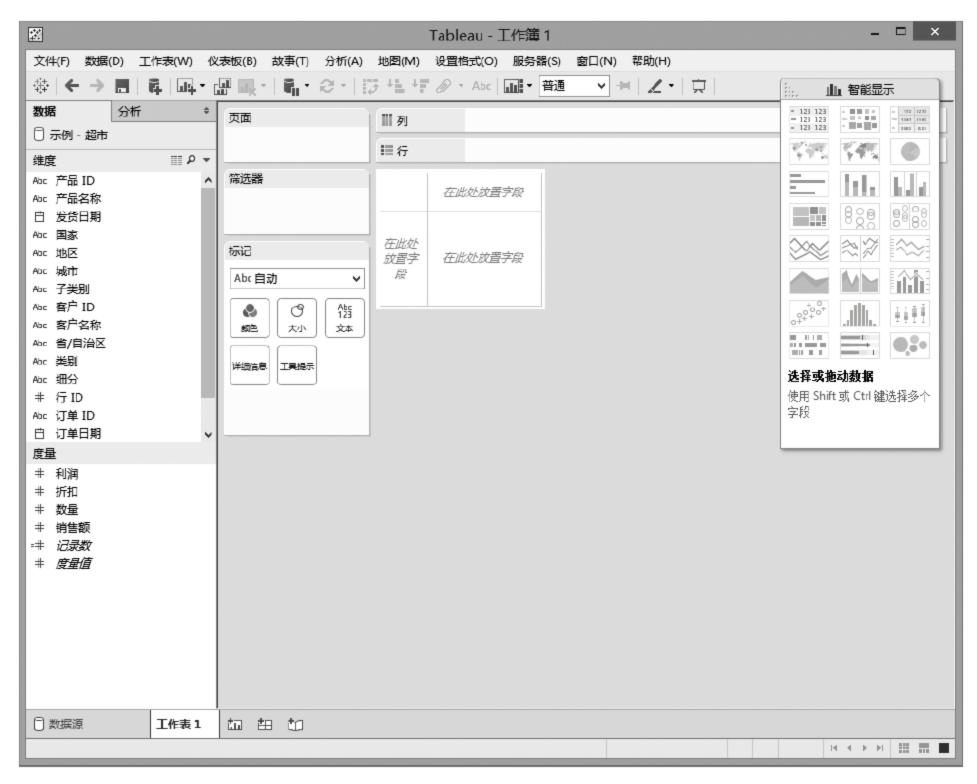


图 10-18 订单中的数据

界面左边就是"订单"这个表格的维度和度量。这里制作一个简单的中国各个地区的利润图表。将国家和地区维度拖到"列",把利润度量拖到"行",即可制作出一个简单的条形图,如图 10-19 所示。

Tableau 最具有特色的功能是拖放式的操作,只需要把维度以及度量拖到适当的位置,即可制作数据图表。单击"智能显示",即可使用同样数据显示成不同图表。例如,单击"填充气泡图",即可制作出漂亮的气泡图,如图 10-20 所示。

用 Excel 制作填充地球图,十分复杂,但是 Tableau 制作填充地球图却十分方便,可以说是一键生成。但是,首先必须先将国家、城市、地区和省/自治区属性改成地理维度。如图 10-21 所示,是一个关于中国各个省份利润的填充地球图,需要将国家和省/自治区维度拖到"列",把利润拖到"行",再单击"智能显示"里的"填充地球图"即可。

接下来可以使用以上几个工作表制作一个中国各个省份地区的利润仪表板。首先,添加一个文本,填写"中国各个省份地区的利润比较图",作为这个仪表板的标题,放在最顶部;然后添加一个水平对象,将地区利润条形图和气球图工作表拖进这个水平对象里,并排放置;最后再将省份利润工作表拖进水平对象的下部。最终得到的仪表板如图 10-22 所示。

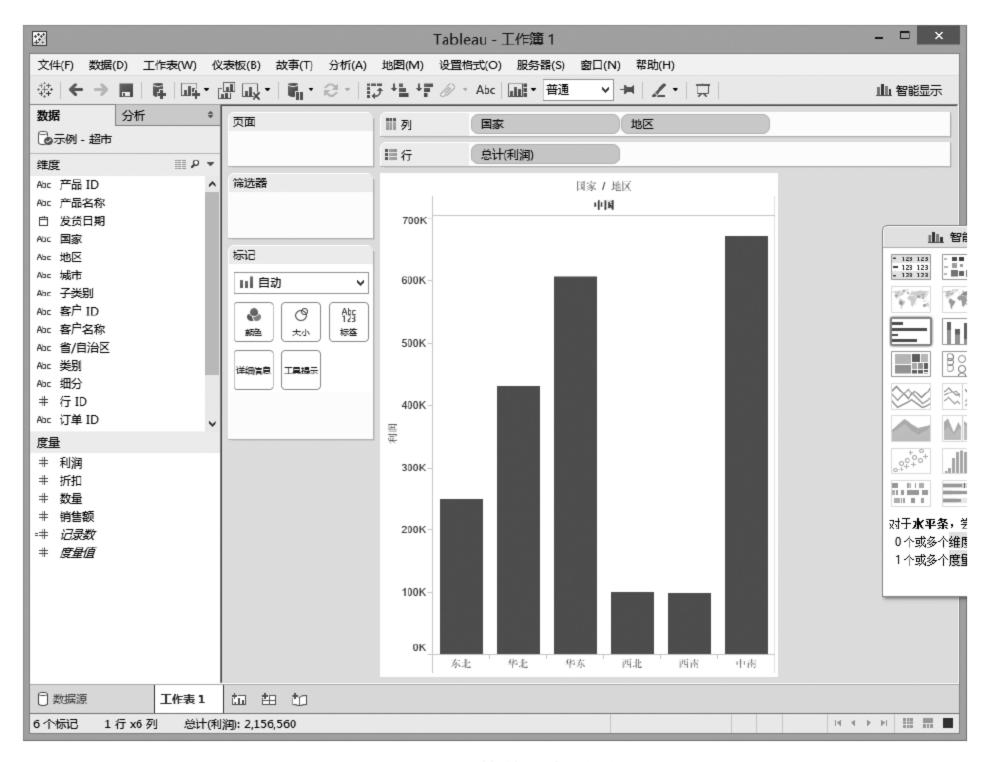


图 10-19 简单的条形图

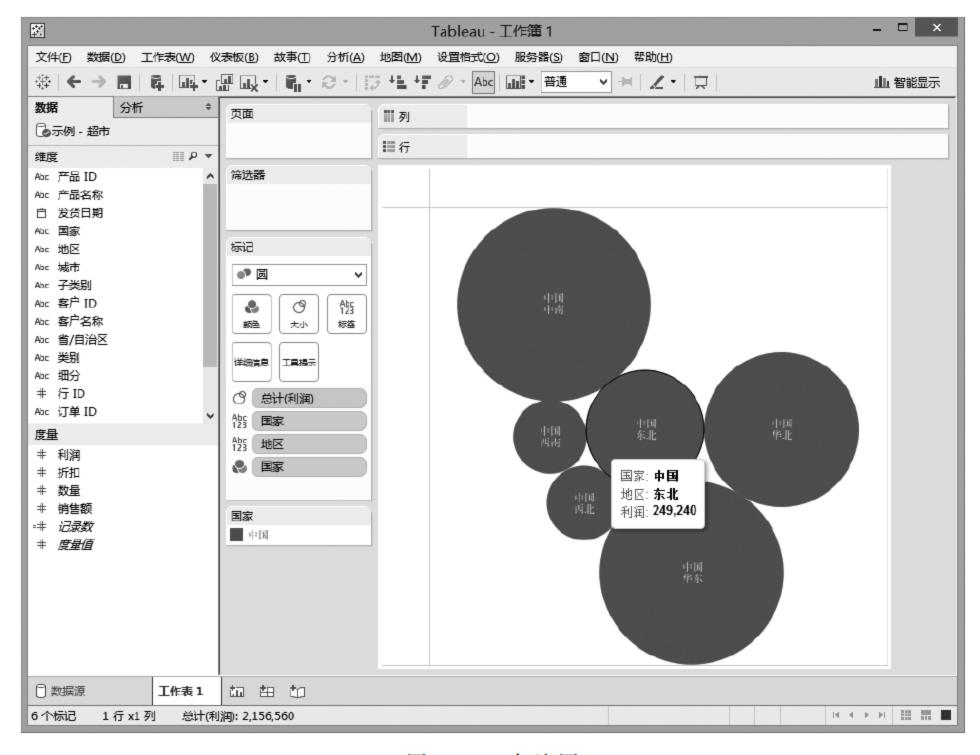


图 10-20 气泡图

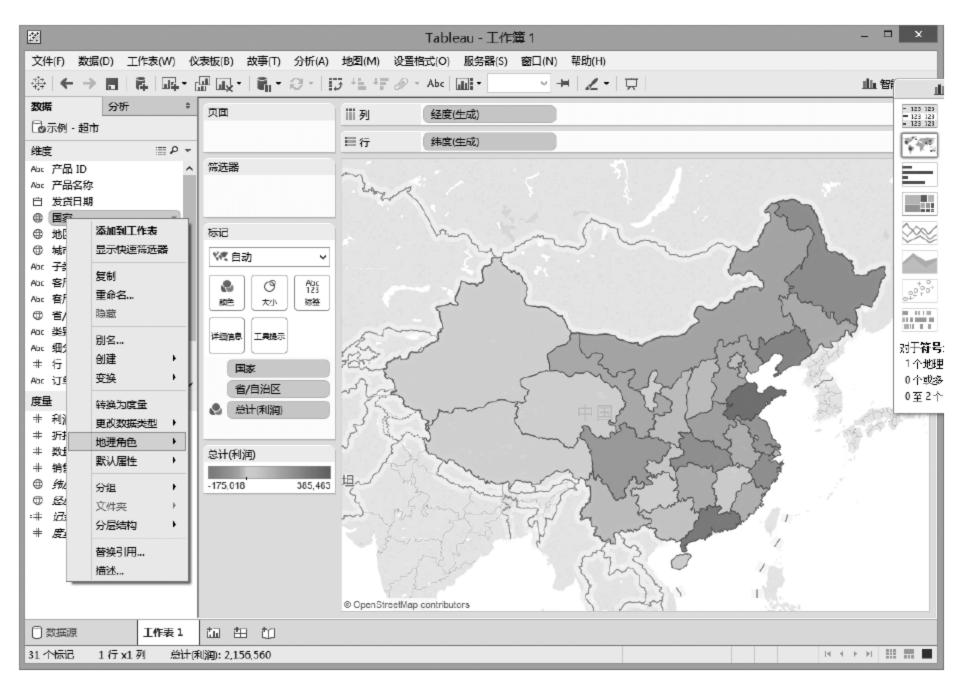


图 10-21 填充地球图

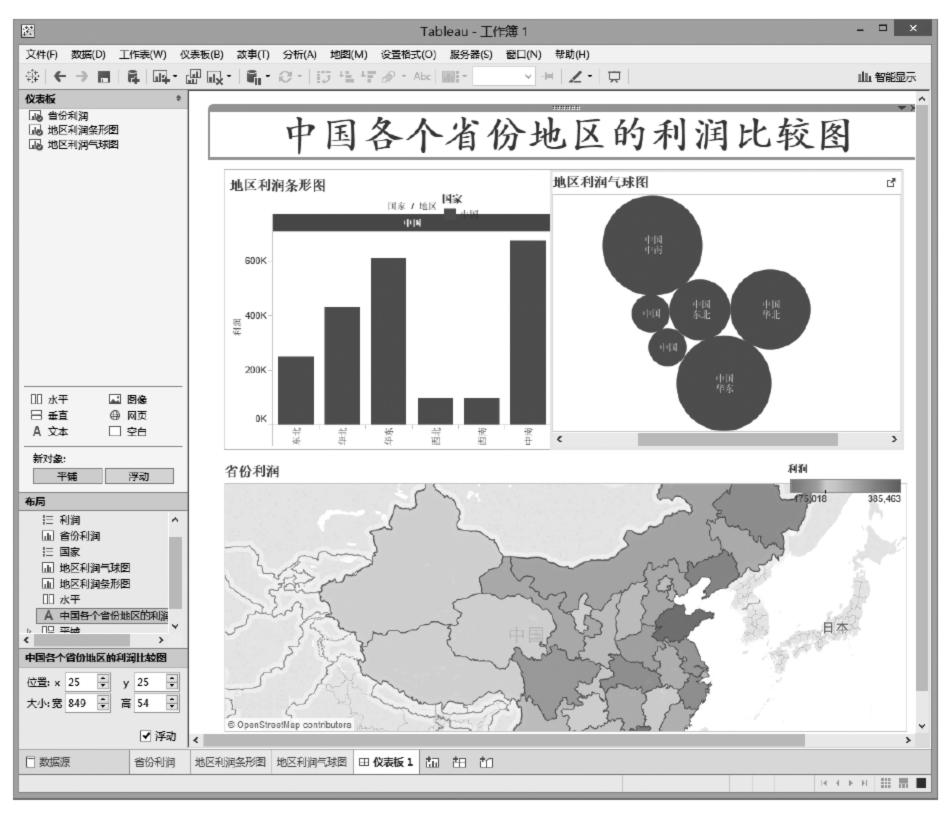


图 10-22 中国各个省份地区的利润比较图

# 10.4 使用"魔镜"制作图表

本节首先简要介绍"魔镜"工具,然后给出一个简单制作实例。

#### 10.4.1 "魔镜"简介

"魔镜"是国云数据旗下的数据可视化产品,底层封装了可视化库接口,用户通过一个直观的拖放界面,就可以创建交互式的图表和完美的仪表盘,并可以通过强大的筛选器分类整理和探索自己的数据。简单拖曳的操作、上选下旋转的功能,可以帮助用户实现各种分析挖掘功能。

"魔镜"拥有丰富的可视化效果,包含 500 多种图形库,涵盖了各种主流的可视化展现形式,绚丽而易读。探索式的分析结合丰富的可视化效果,可以给用户很高的产品体验和视觉感受。以下 4 个图形效果(见图 10-23~图 10-26),选自于魔镜官网,从中可以看出魔镜制作图形的绚丽效果。

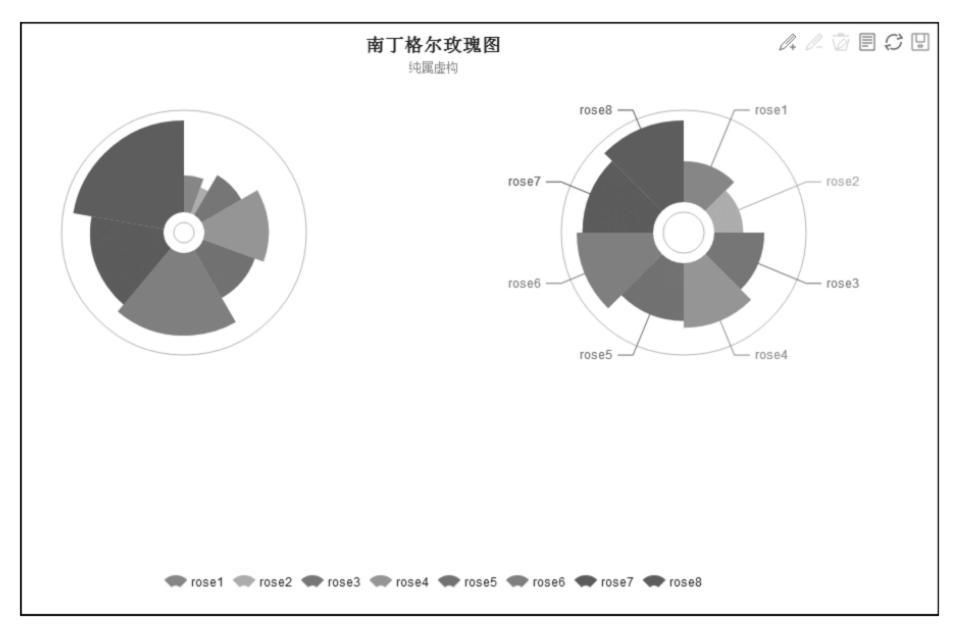


图 10-23 魔镜效果图之一

# 10.4.2 简单制作实例

可以在 Windows 或 Linux 系统中打开浏览器进行可视化图表制作,但是,建议在 Windows 系统下操作,使用起来会更加顺畅。首先登录"魔镜"官方网站(http://www.moojnn.com/),单击网页右上角"登录/注册",先注册一个账号,然后再使用账号登录。登录之后界面如图 10-27 所示。

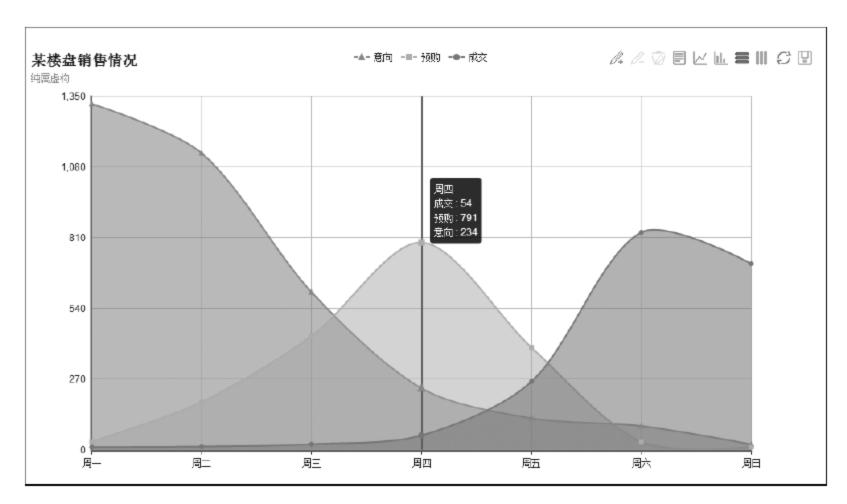


图 10-24 魔镜效果图之二

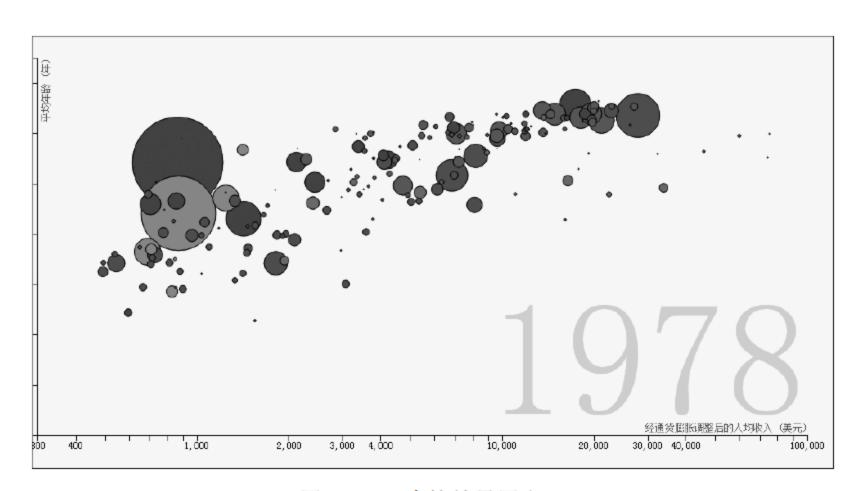


图 10-25 魔镜效果图之三



图 10-26 魔镜效果图之四

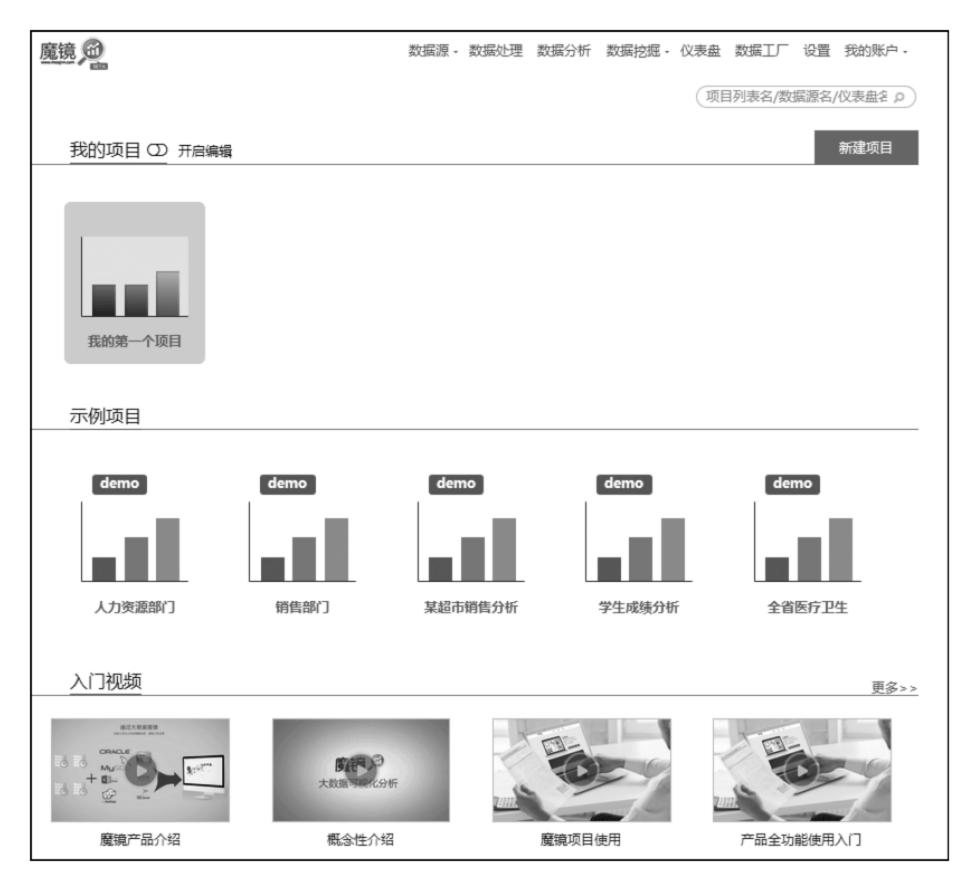


图 10-27 魔镜登录后的页面

这个界面右上角有一个"新建项目"的按钮,单击该按钮即可新建一个项目。界面第一栏为"我的项目",即用户自己制作编辑的项目;第二栏为"示例项目",即魔镜官方提供的一些示例,初学者可以单击进去简单了解,里面有相应数据集制作的绚丽图形,同时可以利用示例的数据集,自己制作一些图形。界面最后一栏为"入门视频"。

接下来,使用一个示例数据集(即一个超市销售样例)制作一些图形,从而可以更好地了解如何使用魔镜。

首先单击"新建项目",输入项目名,数据源可以选择"Excel 表格",导入数据,然后单击 "保存"按钮即可出现个人制作操作台,如图 10-28 所示。

在个人制作操作台界面中,"新建图表"就是用来制作各种各样的图形,而"新建仪表盘"则可以创建用来存放多个图表的面板,用多个数据图表展示数据的某个方面。这里单击"新建图表",即可出现制作图表的工作区,如图 10-29 所示。

在制作图表工作区界面中,左边是数据的两个维度,维度(X轴)为文本属性,度量(Y轴)为数值属性。当需要制作某个图表时,只需要用鼠标将维度拖至箭头指向的"行",将度量拖至箭头指向的"列"(也可以单击维度或度量后面的箭头),然后单击右边框中的各种图表,即可生成相应的图表类型。这里我们分析一下每个地区的销售额和利润,首先将"地区"



图 10-28 个人制作操作台

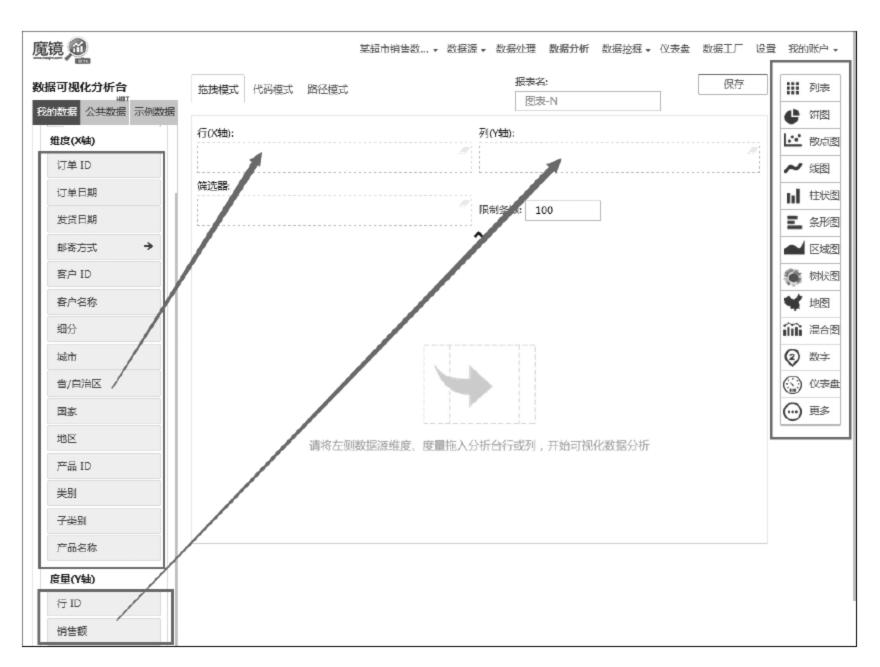


图 10-29 制作新图表的工作区

拖至"行",然后把"销售额"和"利润"拖至"列",单击某种图表即可生成相应的图表,如图 10-30 所示。

魔镜的操作就是如此简单,拖曳数据属性和度量,然后单击图表,就可以一键生成绚丽图表。不过,如果要制作高级的图表,就需要使用魔镜企业版,而企业版需要收费,所以,接下来会介绍基于编程的制作图表代码库 ECharts,属于免费软件,可以轻松制作出高级图表。

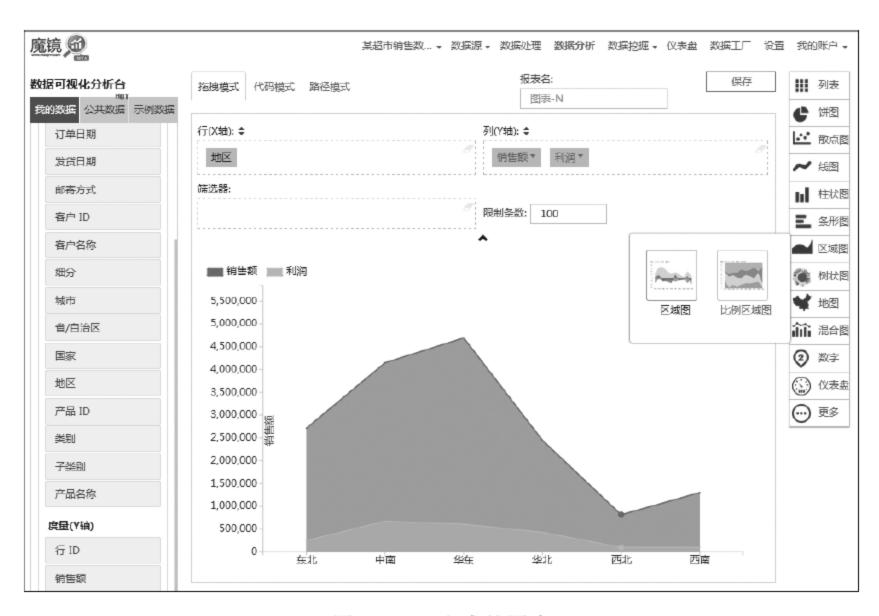


图 10-30 生成的图表

# 10.5 使用 ECharts 制作图表

本节首先简要介绍 ECharts,然后给出 ECharts 图表的制作方法,最后介绍两个制作实例。

# 10.5.1 ECharts 简介

ECharts 是由百度公司前端数据可视化团队研发的图表库,可以流畅地运行在 PC 和移动设备上,兼容当前绝大部分浏览器,底层依赖轻量级的、Canvas 类库 ZRender,可以提供直观、生动、可交互、可高度个性化定制的数据可视化图表。

ECharts 提供了非常丰富的图表类型,包括常规的折线图、柱状图、散点图、饼图、K线图,用于统计的盒形图,用于地理数据可视化的地图、热力图、线图,用于关系数据可视化的关系图、treemap,用于多维数据可视化的平行坐标,以及用于 BI 的漏斗图、仪表盘,并且支持图与图之间的混搭,能够满足用户绝大部分分析数据时的图表制作需求。

# 10.5.2 ECharts 图表制作方法

ECharts 是一款可视化开发库,底层用的是 JavaScript 封装,所以可以在网页 HTML 中嵌入 ECharts 代码来显示数据图表。

#### 1. 下载 ECharts

可以在 Windows 或 Linux 系统中打开浏览器进行可视化图表制作,但是,建议在 Windows 系统下操作,使用起来会更加顺畅。访问 ECharts 官网(http://echarts.baidu.

com/),从官网下载界面选择需要的版本下载,根据开发者的不同需求,官网提供了不同的下载文件。需要注意的是,网站下载的 ECharts 文件名称不是 echarts.js,一般需要手动把文件名称修改为 echarts.js,因为在 HTML 中引入时的名称是 echarts.js。

#### 2. HTML 引入 ECharts

因为 ECharts 底层是 JavaScript, 所以可以像 JavaScript 一样, 直接嵌入到 HTML 中, 如下所示:

#### 3. 绘制一个简单的图表

首先需要为 ECharts 准备一个具备高宽的 DOM 容器;然后就可以通过 echarts. init 方法初始化一个 echarts 实例并通过 setOption 方法生成一个简单的柱状图,具体 HTML 代码如下:

```
<!DOCTYPE html>
<html>
< head>
   <meta charset="utf-8">
    <title>ECharts</title>
   <!--引入 echarts.js-->
   <script src="echarts.js"></script>
< /head>
<body>
   <!--为 ECharts 准备一个具备大小 (宽高)的 DOM-->
   <div id= "main" style= "width: 600px; height: 400px; "></div>
   <script type="text/javascript">
       //基于准备好的 DOM,初始化 echarts 实例
       var myChart=echarts.init(document.getElementById('main'));
       //指定图表的配置项和数据
       var option= {
           title: {
               text: 'ECharts 入门示例'
           },
           tooltip: {},
           legend: {
```

```
data:['销量']
           },
           xAxis: {
              data: ["衬衫","羊毛衫","雪纺衫","裤子","高跟鞋","袜子"]
           },
          yAxis: {},
           series: [{
              name: '销量',
              type: 'bar',
              data: [5, 20, 36, 10, 10, 20]
           }]
       };
       //使用刚指定的配置项和数据显示图表
       myChart.setOption(option);
   </script>
</body>
</html>
```

上述代码文件可以直接从本书官网"下载专区"的"代码"目录的"第 10 章"子目录下载,文件名是 example6. html。为了能够演示这段代码,需要新建一个文件夹,把 echarts. js 文件复制到该文件夹中,同时,在该文件夹中新建一个 HTML 文件(后缀名为. html),把上面这段代码复制到该 HTML 文件中;然后双击该 HTML 文件,即可在浏览器中显示图表。但是,有的计算机会出现中文乱码,可以按照如下方法解决该问题。

- (1) 必须将<head></head>中的<meta charset="utf-8">改为<meta charset="utf-8">改为<meta charset="utf-8">。
- (2) 将 script 代码的字符集改为 GBK,即把语句<script type="text/javascript">改 为<script type="text/javascript" charset="GBK">。

这段 HTML 代码在浏览器中的正常显示效果如图 10-31 所示。

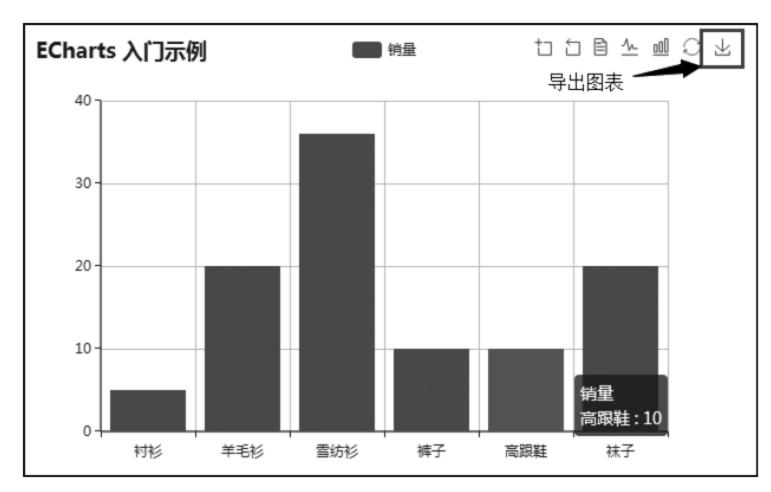


图 10-31 一个简单图表的效果

#### 4. 导出图片

ECharts 可以很方便地导出制作的图表。只要在代码中加入如下代码,即可显示出如图 10-31 右上角所示的工具栏,其中,最右边矩形框中的图标即为"导出图表"的快捷图标,单击该图标就可以顺利完成图表的导出。这段代码可以直接从本书官网的"下载专区"下载,位于"代码"目录的"第 10 章"子目录下,文件名是 toolbox. html。

```
toolbox: {
    show : true,
    feature : {
        dataZoom: {},
        dataView: {readOnly: false},
        magicType: {type: ['line', 'bar']},
        restore: {},
        saveAsImage: {}
}
```

实际上,如果只是简单地制作图表,而不是用于网页中,最简单的办法是打开 ECharts 提供的一个示例,将示例代码清除,直接在示例的编辑器写入新代码即可,而且不会出现乱码,图片导出操作和上面介绍的方法一样。例如,可以打开"微博签到数据点亮中国示例图" (见图 10-32),把编辑框中的代码清除,然后写入自己的代码,单击"运行"选项,也可以显示 ECharts 图表(见图 10-33),非常简单方便。

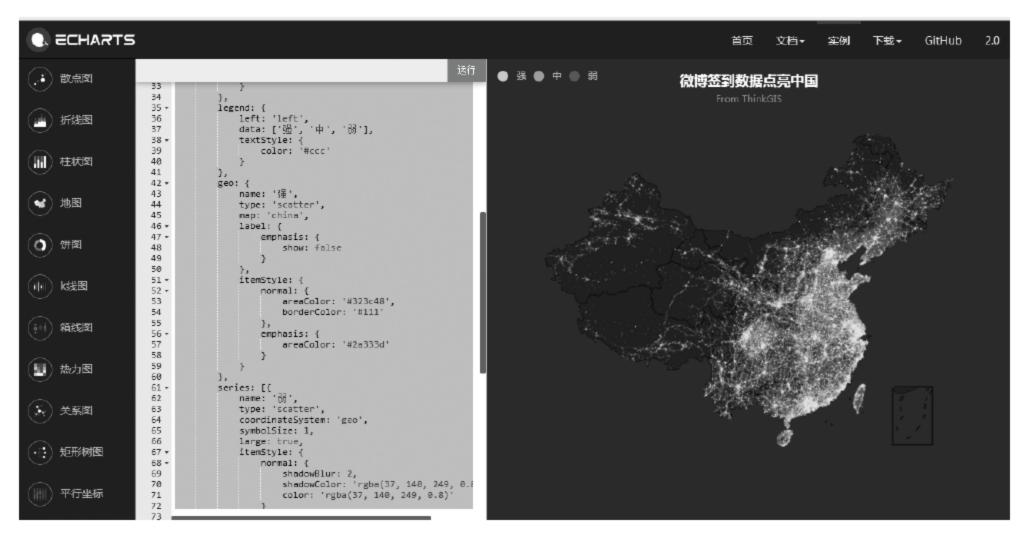


图 10-32 微博签到数据点亮中国示例图

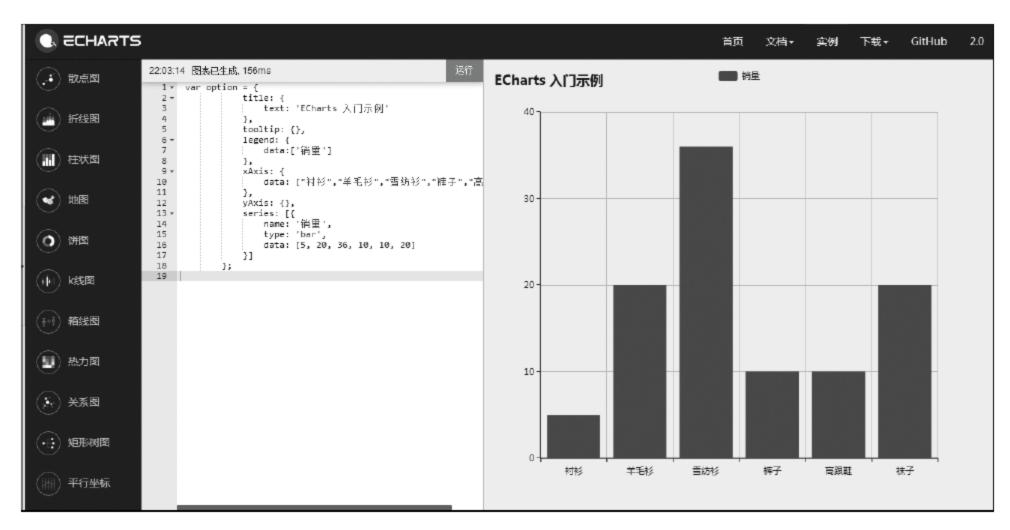


图 10-33 写入自己代码后显示的 ECharts 图表

#### 10.5.3 两个实例

#### 1. 全国主要城市空气质量图

这里制作一个全国主要城市空气质量图(见图 10-34),其中用到的主要城市坐标数据和完整代码,请到本书官网的"下载专区"下载,位于"代码"目录的"第 10 章"子目录下,文件名是"城市空气质量图表中城市坐标.txt""全国主要城市的空气质量.txt"和"城市空气质量图完整代码.txt"。

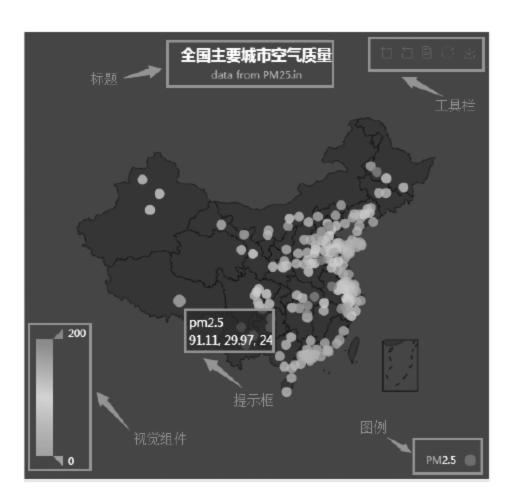


图 10-34 全国主要城市空气质量图

下面分别介绍如何撰写代码生成这张图中的各个元素。

#### 1) 标题组件

标题就是这幅图表所展示的主题,标题分为主标题和副标题,还可以为标题设置链接、

文字属性等,相应的代码如下:

#### 2) 工具栏组件

工具栏是针对制作的图表的一些操作,例如导出图片、数据视图、动态类型切换、数据区域缩放、重置等工具。相应的代码如下:

#### 3) 提示框组件

当单击或者滑过图表中的点线时,弹出关于这些点线的数据信息。相应的代码如下:

```
trigger: 'item' //这个为触发类型,ECharts 支持两种触发类型,'item'为数据项图
形触发,'axis'为坐标轴触发
},
```

#### 4) 图例组件

图例组件展现了不同系列的标记(symbol)、颜色和名字。可以通过单击图例控制哪些系列不显示。相应代码如下:

```
legend: {
    orient: 'vertical', //图例布局方向,有水平和垂直两种
    top: 'bottom', //置于底端
    left: 'right', //同时置于右边
```

#### 5) 视觉组件

视觉组件是用于进行"视觉编码",也就是将数据映射到视觉元素(视觉通道),在图中表现为将数据根据视觉组件映射到不同颜色的图例。相应代码如下:

#### 6) 地图坐标系组件

用于地图的绘制,支持在地理坐标系上绘制散点图、线集。相应代码如下:

```
geo: {
    map: 'china', //地图类型,这里用的是中国地图,ECharts还支持其他地图
    //图形上的文本标签,可用于说明图形的一些数据信息,如值、名称等。在这个地图中,即
    为省的名称
    label: {
        emphasis: {
            show: false //如果改为 true,鼠标浮在省份上,会显示省份的名称
        }
    },
    //地图区域的多边形图形样式,有 normal 和 emphasis两个状态,normal 是图形正常的样式,emphasis是图形高亮的样式,例如,鼠标悬浮或者图例联动高亮的时候会使用
    emphasis作为图形的样式
```

#### 7) 系列列表

介绍了上述各个组件之后,接下来介绍系列列表(series),即在同一个图表上可以制作一系列的多个图表,然后叠在一起,形成一个图表。每个系列通过 type 决定自己的图表类型。ECharts 支持多种图表类型,包括折线图(line)、柱状图(bar)、饼图(pie)、散点(气泡)图(scatter)等。全国主要城市空气质量图采用散点图(scatter)。系列组件还将数据映射到地图的图标,相应代码如下:

```
series: [
                              //这个系列图表的名称
         name: 'pm2.5',
                              //图表的类型,这里使用的是散点(气泡)图
         type: 'scatter'
         coordinateSystem: 'geo', //使用地理坐标系,还有二维坐标系和极坐标系
                              //这是个函数,将数据拼接成指定格式
         data: convertData([
         ]),
                              //图标的大小
         symbolSize: 12,
                            //图形上的文本标签,可用于说明图形的一些数据信息
         label: {
            normal: {
                              //图标上是否显示数值,如果改为 true,则每个图
               show: false
                                标上有相应的数值
            },
            emphasis: {
               show: false
         },
                              //图标的样式
         itemStyle: {
                              //图的高亮样式
            emphasis: {
               borderColor: '#fff', //高亮时的边界颜色
                              //高亮时的边界宽度
               borderWidth: 1
         }
```

#### 其中,用到的数据转换函数定义为

```
var convertData= function (data) {
    var res=[];
    for(var i=0; i<data.length; i++) {
        var geoCoord=geoCoordMap[data[i].name]; //取出城市的坐标
        if (geoCoord) {
            res.push(geoCoord.concat(data[i].value)); //将空气质量值拼接在坐标后面
        }
    }
    return res;
};</pre>
```

制作一张图表,最重要的是数据,没有数据,图表无从谈起,所以在系列(series)里面,需要先将数据转换为指定的格式,在全国空气质量图中,格式为:省份名称+省份坐标+每个省份的空气质量值,然后 ECharts 能自动将数据映射到地图的图标上。

#### 2. 模拟迁徙图

现在制作一个模拟迁徙图(见图 10-35)。用到的数据和完整代码,到本书官网的"下载专区"下载,位于"代码"目录的"第 10 章"子目录下,文件名是"模拟迁徙图图表中城市坐标.txt""北京上海广州三个城市的起点终点数据.txt"和"模拟迁徙图完整代码.txt"。

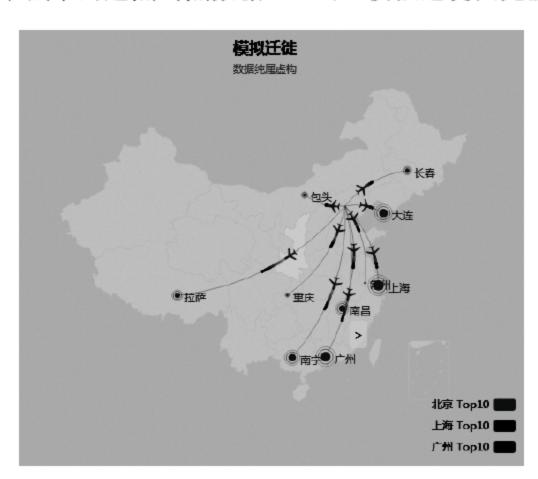


图 10-35 模拟迁徙图

因为之前在"全国主要城市空气质量图"中已经分析了各个组件的代码撰写方法,所以这里就不再赘述。这里主要分析一下系列(series)部分,因为它是图表的主体。

迁徙图使用的还是中国地图,然后在这个地图中使用了3个系列,其中两个是type='lines'的特效线配置,主要是用于设置航线,第三个是type='effectScatter'的带有涟漪特效动画的散点(气泡)图,用于设置每个城市的涟漪效果。也就是说,对于每一个城市的迁徙图,都有三层图形:第一层是航线的特效图,第二、三层为航线图和城市图标涟漪图。接下来先看一下除了数据之外的公共变量以及函数:

```
//这是图中飞机图形的路径,用于设置标记(symbol)
var planePath= 'path://M1705.06,1318.313v-89.2541-319.9-221.79910.073-208.063c0.521-84.
662-26.629-121.796-63.961-121.491c-37.332-0.305-64.482,36.829-63.961,121.49110.073,208.
0631 - 319.9, 221.799v89.2541330.343 - 157.288112.238, 241.3081 - 134.449, 92.93110.531, 42.
0341175.125-42.9171175.125,42.91710.531-42.0341-134.449-92.931112.238-241.308L1705.06,
1318.313z';
//这个函数用于取出 data 中所有数据的起点和终点的坐标
var convertData= function (data) {
    var res=[];
    for(var i=0; i<data.length; i++) {</pre>
        var dataItem=data[i];
       var fromCoord= geoCoordMap[dataItem[0].name];
       var toCoord=geoCoordMap[dataItem[1].name];
        if (fromCoord && toCoord) {
           res.push([{
               coord: fromCoord
           }, {
               coord: toCoord
           }]);
    return res;
};
                                                    //对应图中 3 个城市迁徙图的颜色
var color=['#a6c84c', '#ffa022', '#46bee9'];
                    //3个系列图变量,可以 push 方法将属性添加进 series 中
var series=[];
```

#### 接下来分析第一个系列,即特效点的设置:

```
[['北京', BJData], ['上海', SHData], ['广州', GZData]].forEach(function (item, i) {
//分别将上述 3个 item 传入 function 函数
//并调用 function 函数,目的是绘制 3个城市的迁徙图
   series.push({
                          //系列名称
      name: item[0]+'Top10',
                          //系列使用的图类型
      type: 'lines',
                           //第一层,图表是有分层的,用于更好展示图表
      zlevel: 1,
      effect: {
                          //开启特效,即为图中白色飞点
         show: true,
                          //特效点飞行的时间
         period: 6,
         trailLength: 0.7, //特效点尾部长度
                          //特效颜色,图中为白色
         color: '#ffff',
                          //特效点的大小
         symbolSize: 3
      },
```

然后分析一下第二系列,即飞机飞行路径设置:

```
{
  name: item[0]+'Top10', //系列名称
                    //特效线图
  type: 'lines',
                    //第二层
  zlevel: 2,
                    //图中飞机特效的配置
  effect: {
                    //显示特效
     show: true,
                    //特效动画的时间
     period: 6,
     trailLength: 0, //特效尾迹的长度。取从 0 到 1 的值,数值越大尾迹越长
     symbol: planePath, //飞机图形的路径
                    //飞机的大小
     symbolSize: 15
  },
                     //飞机航线风格
  lineStyle: {
     normal: {
        color: color[i], //飞机航线的颜色
        width: 1, //飞机航线的宽度
        opacity: 0.4, //飞机航线的透明度,为 0时,则不绘制航线
                    //飞机航线的弯曲程度
        curveness: 0.2
     }
  },
  data: convertData(item[1]) //数据,即航线的起点和终点的坐标
},
```

最后第三个系列为图中涟漪效果的设置,采用带有涟漪特效动画的散点(气泡)图,代码如下:

```
name: item[0]+'Top10', //系列名称
type: 'effectScatter', //系列使用图表类型
coordinateSystem: 'geo', //系列使用坐标类型,这里没地图坐标
zlevel: 2, //第二层
rippleEffect: {
```

```
//波纹的填充方式,可以设置为'stroke'和'fill','stroke'只是
      brushType: 'stroke'
                          在点外围设置涟漪,'fill'涟漪填充更圆满
   },
                        //设置图标说明文字
   label: {
      normal: {
          show: true,
          position: 'right',//文字在图标右边
          formatter: '{b}' //设置显示的文字,可以设置 {a}、{b}、{c},分别表示系列名、数据
                          名、数据值
   },
   symbolSize: function (val) {
                        //根据每个节点的值,设置涟漪节点的大小
      return val[2] / 8;
   },
   itemStyle: {
      normal: {
          color: color[i] //设置涟漪节点的颜色
      }
   },
   data: item[1].map(function (dataItem) {
                        //设置数据,即为每个省份的名称+省份坐标+省份的值
      return {
          name: dataItem[1].name,
          value: geoCoordMap[dataItem[1].name].concat([dataItem[1].value])
      };
   })
});
```

模拟迁徙图比之前的全国主要城市空气质量图难度大,因为模拟迁徙图用到了3个系列图表,即用了3种类型的图表层叠在一起,形成一幅图表。

# 10.6 本章小结

数据可视化在大数据分析中具有非常重要的作用,尤其从用户角度而言,它是提升用户数据分析效率的有效手段。可视化工具包括信息图表工具、地图工具和高级分析工具等,每种工具都可以帮助人们实现不同类型的数据可视化分析,可以根据具体应用场合来选择适合的工具。

本章选取了 5 种具有代表性的可视化工具,包括 Easel. ly、D3、Tableau、魔镜、ECharts等,简要介绍了这些工具的使用方法。这些工具中,只有 Tableau 只能在 Windows 系统下使用,暂时不支持 Linux 系统,其他工具由于都是基于浏览器的,都可以同时在 Linux 和 Windows 系统下使用。

# 第 11 章

# 数据采集工具的安装和使用

数据采集是大数据分析全流程的重要环节,典型的数据采集工具包括 ETL 工具、日志采集工具(如 Flume 和 Kafka)、数据迁移工具(如 Sqoop)等。本章重点选择了具有代表性的数据采集工具进行介绍,包括日志采集工具 Flume、Kafka 和数据迁移工具 Sqoop,详细介绍这些工具的安装和使用方法,同时给出相关实例来加深对工具作用及其使用方法的理解。

#### 11.1 Flume

Flume 是 Cloudera 提供的一个高可用的、高可靠的、分布式的海量日志采集、聚合和传输的系统,Flume 支持在日志系统中定制各类数据发送方,用于收集数据;同时,Flume 提供对数据进行简单处理,并写到各种数据接收方(可定制)的能力。

## 11.1.1 安装 Flume

#### 1. 下载安装文件

登录 Linux 系统,在 Linux 系统中(不是 Windows 系统)中打开火狐浏览器,访问网址 http://www.apache.org/dyn/closer.lua/flume/1.7.0/apache-flume-1.7.0-bin.tar.gz,下载 Flume 安装文件;或者也可以访问本书官网的"下载专区",在"软件"目录下下载 Flume 安装文件 apache-flume-1.7.0-bin.tar.gz。火狐浏览器会默认把下载文件都保存到当前用户的下载目录,由于本书全部采用 hadoop 用户登录 Linux 系统,所以,apache-flume-1.7.0-bin.tar.gz 文件会被保存到"/home/hadoop/下载/"目录下。

需要注意的是,如果是在 Windows 系统下面下载安装文件 apache-flume-1.7.0-bin. tar. gz,则需要通过 FTP 软件上传到 Linux 系统的"/home/hadoop/下载/"目录下,这个目录是本书所有安装文件的中转站。

下载完安装文件以后,需要对文件进行解压。按照 Linux 系统使用的默认规范,用户安装的软件一般都是存放在/usr/local/目录下。使用 hadoop 用户登录 Linux 系统,打开一个终端,执行如下命令:

\$cd ~

\$sudo tar - zxvf ./下载/apache-flume-1.7.0-bin.tar.gz - C /usr/local

**注意**:将 apache-flume-1.7.0-bin. tar. gz 解压到/usr/local 目录下,命令中一定要加上-C,否则会出现归档找不到的错误。

然后将解压的文件的名称修改为 flume,以简化操作,不用每次都输入很长的文件名,命令如下:

\$cd /usr/local

\$sudo mv ./apache-flume-1.7.0-bin ./flume

#### 2. 配置环境变量

使用 vim 编辑器打开~/. bashrc 文件,命令如下:

\$sudo vim ~/.bashrc

然后在该文件开头加入如下代码:

export JAVA HOME=/usr/lib/jvm/java-8-openjdk-amd64;

export FLUME HOME=/usr/local/flume

export FLUME CONF DIR=\$FLUME HOME/conf

export PATH= \$PATH: \$FLUME\_HOME/bin

需要注意的是,本书中,在各个章节都有对~/. bashrc 文件进行修改。如果之前已经在该文件中增加了其他内容,不要删除,只要把上面 4 行内容继续增加到该文件开头即可,另外,如果之前已经在该文件中加入"export JAVA\_HOME =/usr/lib/jvm/java-8-openjdk-amd64;"这行语句,那么,这里就不用重复添加这行语句。

接下来执行如下命令使环境变量立即生效:

\$source ~/.bashrc

然后修改配置文件 flume-env. sh,命令如下:

\$cd /usr/local/flume

\$sudo mvflume - env.sh.template flume-env.sh

\$sudo vim flume-env.sh

在 flume-env. sh 文件开头加入如下语句:

export JAVA\_HOME=/usr/lib/jvm/java-8-openjdk-amd64;

#### 3. 启动 Flume

执行如下语句启动 Flume:

```
$cd /usr/local/flume
$./bin/flume-ng version
```

启动成功后,会出现如图 11-1 所示的信息。

```
Flume 1.7.0

Source code repository: https://git-wip-us.apache.org/repos/asf/flume.git
Revision: 511d868555dd4d16e6ce4fedc72c2d1454546707

Compiled by bessbd on Wed Oct 12 20:51:10 CEST 2016
From source with checksum 0d21b3ffdc55a07e1d08875872c00523
```

图 11-1 Flume 启动成功后的信息

需要注意的是,如果系统里之前已经安装了 HBase,按照上述方法配置启动后会出现错误:"找不到或无法加载主类 org. apache. flume. tools. GetJavaProperty"。可以通过修改 hbase-env. sh 文件来解决这个错误,首先使用 vim 编辑器打开 hbase-env. sh 文件,命令如下:

```
$cd /usr/local/hbase/conf
$sudo vim hbase-env.sh
```

在 hbase-env. sh 文件中找到下面这一行内容:

```
export HBASE_CLASSPATH=/home/hadoop/hbase/conf
```

然后把这行语句注释掉,即在语句前面加上一个#,添加以后的效果如下:

```
#export HBASE CLASSPATH=/home/hadoop/hbase/conf
```

最后保存该文件并退出 vim 编辑器。通过这种方式,就可以顺利启动 Flume。

# 11.1.2 两个实例

#### 1. 使用 Flume 接收来自 AvroSource 的信息

AvroSource 可以发送一个给定的文件给 Flume, Flume 接收到以后可以进行相应的处理, 例如显示到屏幕上。

1) 创建 Agent 配置文件

使用如下命令在/usr/local/flume/conf 目录下创建一个新文件 avro. conf:

```
$cd /usr/local/flume
$sudo vim ./conf/avro.conf
```

然后在 avro. conf 文件中写入以下内容:

```
al.sources=r1
```

al.sinks=k1

```
al.channels=cl
#Describe/configure the source
al.sources.rl.type=avro
al.sources.rl.bind=0.0.0.0
al.sources.rl.bind=0.0.0.0
al.sources.rl.port=4141 #注意这个端口名,在后面会用到
#Describe the sink
al.sinks.kl.type=logger
#Use a channel which buffers events in memory
al.channels.cl.type=memory
al.channels.cl.type=to00
al.channels.cl.transactionCapacity=100
#Bind the source and sink to the channel
al.sources.rl.channels=cl
al.sinks.kl.channel=cl
```

上述代码也可以直接到本书官网"下载专区"下载,位于"代码"目录的"第 11 章"子目录下,文件名是 avro. conf。

2) 启动 Flume Agent al 执行如下命令启动日志控制台:

```
$/usr/local/flume/bin/flume- ng agent - c .- f /usr/local/flume/conf/avro.conf
- n al- Dflume.root.logger= INFO, console
```

执行该命令以后,屏幕上会出现如图 11-2 所示的信息。

```
. 

Terminal File Edit View Search Terminal Help
16/11/23 14:27:03 INFO sink.DefaultSinkFactory: Creating instance of sink: k1,
ype: logger
16/11/23 14:27:03 INFO node.AbstractConfigurationProvider: Channel c1 connected
to [r1, k1]
16/11/23 14:27:03 INFO node.Application: Starting new configuration:{ sourceRunn
ers:{r1=EventDrivenSourceRunner: {    source:Avro source r1: {        bindAddress: 0.0.0.0
, port: 4141 } }} sinkRunners:{k1=SinkRunner: {    policy:org.apache.flume.sink.Def
aultSinkProcessor@59f04730 counterGroup:{    name:null counters:{}    }  }}  channels:{c
1=org.apache.flume.channel.MemoryChannel{name: c1}} }
16/11/23 14:27:03 INFO node.Application: Starting Channel c1
16/11/23 14:27:03 INFO instrumentation.MonitoredCounterGroup: Monitored counter
group for type: CHANNEL, name: c1: Successfully registered new MBean.
16/11/23 14:27:03 INFO instrumentation.MonitoredCounterGroup: Component type: CH
ANNEL, name: c1 started
16/11/23 14:27:03 INFO node.Application: Starting Sink k1
16/11/23 14:27:03 INFO node.Application: Starting Source r1
16/11/23 14:27:03 INFO source.AvroSource: Starting Avro source r1: { bindAddress
: 0.0.0.0, port: 4141 }...
16/11/23 14:27:04 INFO instrumentation.MonitoredCounterGroup: Monitored counter
group for type: SOURCE, name: r1: Successfully registered new MBean.
16/11/23 14:27:04 INFO instrumentation.MonitoredCounterGroup: Component type: SO
URCE, name: r1 started
16/11/23 14:27:04 INFO source.AvroSource: Avro source r1 started.
```

图 11-2 启动日志控制台后的屏幕信息

#### 3) 创建指定文件

打开另外一个 Linux 终端,使用如下命令在/usr/local/flume 目录下新建一个文件 log.

00,并在文件中加入一行内容"hello world":

```
$cd /usr/local/flume
$sudo sh - c 'echo "hello world" > /usr/local/flume/log.00'
```

再打开另外一个 Linux 终端,执行如下命令:

```
$cd /usr/local/flume
$./bin/flume-ng avro-client --conf conf -H localhost -p 4141 -F /usr/local/
flume/log.00
```

在该命令中,4141 是前面在 avro. conf 文件里写入的端口号。

执行该命令以后,AvroSource 就向 Flume 发送了一个文件,这时可以切换到之前的日志控制台所在的终端窗口,就可以看到 Flume 已经接收到了信息,如图 11-3 所示。

```
7.0.0.1:4141 DISCONNECTED
16/11/23 08:13:23 INFO ipc.NettyServer: [id: 0x81e59348, /127.0.0.1:47578 :> /12
7.0.0.1:4141] UNBOUND
16/11/23 08:13:23 INFO ipc.NettyServer: [id: 0x81e59348, /127.0.0.1:47578 :> /12
7.0.0.1:4141] CLOSED
16/11/23 08:13:23 INFO ipc.NettyServer: Connection to /127.0.0.1:47578 disconnec
16/11/23 08:13:50 INFO ipc.NettyServer: [id: 0xf0609c2d, /127.0.0.1:47590 => /12
7.0.0.1:4141] OPEN
16/11/23 08:13:50 INFO ipc.NettyServer: [id: 0xf0609c2d, /127.0.0.1:47590 => /12
7.0.0.1:4141] BOUND: /127.0.0.1:4141
16/11/23 08:13:50 INFO ipc.NettyServer: [id: 0xf0609c2d, /127.0.0.1:47590 => /12
7.0.0.1:4141] CONNECTED: /127.0.0.1:47590
16/11/23 08:13:50 INFO ipc.NettyServer: [id: 0xf0609c2d, /127.0.0.1:47590 :> /12
7.0.0.1:4141] DISCONNECTED
16/11/23 08:13:50 INFO ipc.NettyServer: [id: 0xf0609c2d, /127.0.0.1:47590 :> /12
7.0.0.1:4141] UNBOUND
16/11/23 08:13:50 INFO ipc.NettyServer: [id: 0xf0609c2d, /127.0.0.1:47590 :> /12
7.0.0.1:4141] CLOSED
16/11/23 08:13:50 INFO ipc.NettyServer: Connection to /127.0.0.1:47590 disconnec
16/11/23 08:13:53 INFO sink.LoggerSink: Event: { headers:{} body: 68 65 6C 6C 6F
 20 77 6F 72 6C 64
                                  hello world }
```

图 11-3 日志控制台终端窗口内的信息

在图 11-3 的最后一行,可以看到 Flume 已经成功地接收到了"hello world"。

#### 2. 使用 Flume 接收来自 NetcatSource 的信息

NetcatSource 可以把用户实时输入的信息不断地发送给 Flume, Flume 接收到以后可以进行相应的处理,例如显示到屏幕上。

1) 创建 agent 配置文件

执行如下命令,在/usr/local/flume/conf/目录下新建 example.conf 文件:

```
$cd /usr/local/flume
$sudo vim ./conf/example.conf
```

在 example. conf 文件里写入以下内容:

```
#example.conf: A single-node Flume configuration
#Name the components on this agent
al.sources=rl
al.sinks=kl
al.channels=cl
#Describe/configure the source
al.sources.rl.type=netcat
al.sources.rl.bind=localhost
al.sources.rl.port=44444 #记住该端口号,后面会用到
#Describe the sink
al.sinks.kl.type=logger
#Use a channel which buffers events in memory
al.channels.cl.type=memory
al.channels.cl.capacity=1000
al.channels.cl.transactionCapacity=100
#Bind the source and sink to the channel
al.sources.rl.channels=cl
al.sinks.kl.channel=cl
```

上述代码也可以直接到本书官网"下载专区"下载,位于"代码"目录的"第 11 章"子目录下,文件名是 example. conf。

2) 启动 Flume Agent a1 执行如下命令启动日志控制台:

```
$/usr/local/flume/bin/flume-ng agent --conf ./conf --conf-file ./example.
conf --name al-Dflume.root.logger=INFO,console
```

执行该命令以后会出现如图 11-4 所示的屏幕信息。

```
X _ D Terminal File Edit View Search Terminal Help
el c1 type memory
16/11/23 14:44:46 INFO node.AbstractConfigurationProvider: Created channel c1
16/11/23 14:44:46 INFO source.DefaultSourceFactory: Creating instance of source
16/11/23 14:44:46 INFO sink.DefaultSinkFactory: Creating instance of sink: k1, t
ype: logger
16/11/23 14:44:46 INFO node.AbstractConfigurationProvider: Channel c1 connected
to [r1, k1]
16/11/23 14:44:46 INFO node.Application: Starting new configuration:{ sourceRunn
ame:r1,state:IDLE} }} sinkRunners:{k1=SinkRunner: { policy:org.apache.flume.sink
.DefaultSinkProcessor@4535df6d counterGroup:{ name:null counters:{} } }} channel
s:{c1=org.apache.flume.channel.MemoryChannel{name: c1}} }
16/11/23 14:44:46 INFO node.Application: Starting Channel c1
16/11/23 14:44:46 INFO instrumentation.MonitoredCounterGroup: Monitored counter
group for type: CHANNEL, name: c1: Successfully registered new MBean.
16/11/23 14:44:46 INFO instrumentation.MonitoredCounterGroup: Component type: CH
ANNEL, name: c1 started
16/11/23 14:44:46 INFO node.Application: Starting Sink k1
16/11/23 14:44:46 INFO node.Application: Starting Source r1
16/11/23 14:44:46 INFO source.NetcatSource: Source starting
16/11/23 14:44:46 INFO source.NetcatSource: Created serverSocket:sun.nio.ch.Serv
erSocketChannelImpl[/127.0.0.1:44444]
```

图 11-4 启动日志控制台后屏幕显示的信息

再打开一个终端,输入如下命令:

```
$telnet localhost 44444
```

该命令中的 44444 是前面写入到 example. conf 文件中的端口号。执行该命令以后,会出现如图 11-5 所示的信息。

```
X _ D Terminal File Edit View Search Terminal Help

dblab@ubuntu:~$ telnet localhost 44444

Trying 127.0.0.1...

Connected to localhost.

Escape character is '^]'.
```

图 11-5 执行 telnet 命令后的屏幕信息

为了方便区分,这里把这个终端窗口称为"NetcatSource 终端窗口";然后可以在这个 NetcatSource 终端窗口中输入任何字符,这个窗口里输入的字符都会被实时发送到 Flume Agent a1,另外一个"日志控制台"终端窗口也会同步显示输入的内容,例如,在 NetcatSource 终端窗口输入"hello world",如图 11-6 所示。

```
Idblab@ubuntu:~$ telnet localhost 44444
Trying 127.0.0.1...
Connected to localhost.
Escape character is '^]'.
hello world
OK
```

图 11-6 在 NetcatSource 终端窗口输入"hello world"

"日志控制台"终端窗口也会同步显示"hello world",如图 11-7 所示。

```
🗙 🔲 🏻 Terminal File Edit View Search Terminal Help
 6/11/23 14:44:46 INFO source.DefaultSourceFactory: Creating instance of source
r1, type netcat
16/11/23 14:44:46 INFO sink.DefaultSinkFactory: Creating instance of sink: k1, t
ype: logger
16/11/23 14:44:46 INFO node.AbstractConfigurationProvider: Channel c1 connected
to [r1, k1]
16/11/23 14:44:46 INFO node.Application: Starting new configuration:{ sourceRunn
ame:r1,state:IDLE} }} sinkRunners:{k1=SinkRunner: { policy:org.apache.flume.sink
.DefaultSinkProcessor@4535df6d counterGroup:{    name:null counters:{} } }} channel
s:{c1=org.apache.flume.channel.MemoryChannel{name: c1}} ]
16/11/23 14:44:46 INFO node.Application: Starting Channel c1
16/11/23 14:44:46 INFO instrumentation.MonitoredCounterGroup: Monitored counter
group for type: CHANNEL, name: c1: Successfully registered new MBean.
16/11/23 14:44:46 INFO instrumentation.MonitoredCounterGroup: Component type: CH
ANNEL, name: c1 started
16/11/23 14:44:46 INFO node.Application: Starting Sink k1
16/11/23 14:44:46 INFO node.Application: Starting Source r1 16/11/23 14:44:46 INFO source.NetcatSource: Source starting
16/11/23 14:44:46 INFO source.NetcatSource: Created serverSocket:sun.nio.ch.Serv
erSocketChannelImpl[/127.0.0.1:44444]
16/11/23 14:51:56 INFO sink.LoggerSink: Event: { headers:{} body: 68 65 6C 6C 6F
20 77 6F 72 6C 64 0D
                                 hello world. }
```

图 11-7 "日志控制台"终端窗口会同步显示"hello world"

从图 11-7 中可以看出,最后一行已经成功显示了"hello world"。 需要补充说明的是,Flume 只能传递英文和字符,不能输入中文。

#### 11.2 Kafka

Kafka 是一种高吞吐量的分布式发布订阅消息系统,它可以处理消费者规模的网站中的所有动作流数据。Kafka 的目的是通过 Hadoop 和 Spark 等的并行加载机制来统一线上和离线的消息处理。

# 11.2.1 Kafka 相关概念

为了更好地理解和使用 Kafka,这里介绍一下 Kafka 的相关概念。

- (1) Broker: Kafka 集群包含一个或多个服务器,这些服务器称为 Broker。
- (2) Topic: 每条发布到 Kafka 集群的消息都有一个类别,这个类别称为 Topic。物理上不同 Topic 的消息分开存储,逻辑上一个 Topic 的消息虽然保存于一个或多个 Broker上,但用户只需指定消息的 Topic,即可生产或消费数据,而不必关心数据存于何处。
  - (3) Partition: 是物理上的概念,每个 Topic 包含一个或多个 Partition。
  - (4) Producer: 负责发布消息到 Kafka Broker。
  - (5) Consumer: 消息消费者,向 Kafka Broker 读取消息的客户端。
- (6) Consumer Group: 每个 Consumer 属于一个特定的 Consumer Group,可为每个 Consumer 指定 group name,若不指定 group name 则属于默认的 group。

#### 11.2.2 安装 Kafka

访问 Kafka 官网下载页面(https://kafka.apache.org/downloads),下载 Kafka 稳定版本 0.10.1.0 的安装包 kafka\_2.10-0.10.1.0.tgz,此安装包内已经附带 Zookeeper,不需要额外安装 Zookeeper;或者也可以访问本书官网的"下载专区","软件"目录下下载 Kafka 安装文件 kafka\_2.10-0.10.1.0.tgz。

下载完安装文件以后,需要对文件进行解压。按照 Linux 系统使用的默认规范,用户安装的软件一般都是存放在/usr/local/目录下。使用 hadoop 用户登录 Linux 系统,打开一个终端,执行如下命令:

\$cd ~/下载

\$sudo tar -zxf kafka\_2.10-0.10.1.0.tgz -C /usr/local

\$cd /usr/local

\$sudo mv kafka 2.10-0.10.1.0/ ./kafka

\$sudo chown -R hadoop ./kafka

# 11.2.3 一个实例

新建一个 Linux 终端,执行如下命令启动 Zookeeper:

\$cd /usr/local/kafka

\$bin/zookeeper-server-start.sh config/zookeeper.properties

**注意**:执行上面命令以后,终端窗口会返回一堆信息,然后就停住不动,没有回到 shell 命令提示符状态,这时,千万不要错误地认为死机了,而是 Zookeeper 服务器启动了,正在处于服务状态。所以,千万不要关闭这个终端窗口,一旦关闭,Zookeeper 服务就停止了。

然后新建第二个终端,输入如下命令启动 Kafka:

\$cd /usr/local/kafka

\$./bin/kafka-server-start.sh config/server.properties

同样,执行上面命令以后,终端窗口会返回一堆信息,然后就停住不动了,没有回到 shell 命令提示符状态,这时,千万不要错误地认为死机了,而是 Kafka 服务器启动了,正在 处于服务状态。所以,千万不要关闭这个终端窗口,一旦关闭,Kafka 服务就停止了。

新建第三个终端,输入如下命令:

\$cd /usr/local/kafka

\$./bin/kafka-topics.sh --create --zookeeper localhost:2181 --replicationfactor 1 --partitions 1 -- topic dblab

topic 是发布消息发布的 category,以单节点的配置方式创建了一个名为 dblab 的 topic。可以用 list 命令列出所有创建的 topics,来查看刚才创建的 topic 是否存在,命令如下:

\$cd /usr/local/kafka

\$./bin/kafka-topics.sh --list --zookeeper localhost:2181

可以在结果中查看到,dblab 这个 topic 已经存在。接下来用 producer 生产一些数据,命令如下:

\$cd /usr/local/kafka

\$./bin/kafka-console-producer.sh --broker-list localhost:9092 --topic dblab

该命令执行后,可以在该终端中输入以下信息作为测试:

hello hadoop

hello xmu

hadoop world

然后再次开启新的第四个终端,输入如下命令使用 consumer 来接收数据:

\$cd /usr/local/kafka

\$./bin/kafka-console-consumer.sh --zookeeper localhost:2181 --topic dblab --

from-beginning

执行该命令以后,就可以看到刚才在另外一个终端的 producer 产生的三条信息"hello

hadoop" "hello xmu"和"hello world",说明 Kafka 安装成功。

# 11.3 **Sqoop**

Sqoop 是一款开源的工具,主要用于在 Hadoop 与传统的关系数据库之间进行数据的传递,可以将一个关系数据库(如 MySQL、Oracle、PostgreSQL等)中的数据导入到 Hadoop 的 HDFS、HBase、Hive 中,也可以将 Hadoop 的数据导入到关系数据库中。 Sqoop 项目开始于 2009 年,最早是作为 Hadoop 的一个第三方模块存在,后来为了让使用者能够快速部署,也为了让开发人员能够更快速地迭代开发,Sqoop 独立成为一个 Apache 项目。

Sqoop 的安装环境如下。

- (1) 操作系统: Linux 系统(建议 Ubuntu 16.04)。
- (2) Sqoop: 1.4.6 版本。
- (3) Hadoop: 2.7.1 版本。
- (4) MySQL: 5.7.15 版本。

需要注意的是,Sqoop1 与 Sqoop2 完全不兼容,1.4.6 及之前的版本是 Sqoop1,之后的版本是 Sqoop2。本书使用 Sqoop1.4.6。

#### 11.3.1 下载安装文件

登录 Linux 系统(本书是使用 hadoop 用户名登录),然后在 Linux 的浏览器(一般自带的是火狐浏览器)中,访问 Sqoop 官网(http://sqoop.apache.org/),下载 Sqoop 安装文件 sqoop-1.4.6. bin\_hadoop-2.0.4-alpha.tar.gz;或者也可以访问本书官网的"下载专区","软件"目录下下载 Sqoop 安装文件 sqoop-1.4.6. bin\_hadoop-2.0.4-alpha.tar.gz。火狐浏览器会默认把下载文件都保存到当前用户的下载目录,由于本书全部采用 hadoop 用户登录 Linux 系统,所以,sqoop-1.4.6. bin\_hadoop-2.0.4-alpha.tar.gz 文件会被保存到"/home/hadoop/下载/"目录下。

执行如下命令,完成安装文件解压缩:

```
$cd ~/下载
```

\$sudo tar - zxvf sqoop-1.4.6.bin hadoop-2.0.4-alpha.tar.gz - C /usr/local

将解压的文件的名称修改为 sqoop,以简化操作,不用每次都输入很长的文件名,命令如下:

\$cd /usr/local

\$sudo mv sqoop-1.4.6.bin\_hadoop-2.0.4-alpha sqoop

接下来把 sqoop 文件夹的权限赋予当前的 hadoop 用户,命令如下:

\$sudo chown - R hadoop:hadoop sqoop

#### 11.3.2 修改配置文件

执行如下命令把/usr/local/sqoop/conf 目录下的配置文件 sqoop-env-template. sh 复制一份,并命名为 sqoop-env. sh:

\$cd sqoop/conf/
\$cat sqoop-env-template.sh >> sqoop-env.sh

使用 vim 编辑器打开 sqoop-env. sh 文件进行编辑:

\$cd /usr/local/sqoop/conf/
\$vim sqoop-env.sh

在 sqoop-env. sh 文件中添加如下配置信息:

exportHADOOP\_COMMON\_HOME=/usr/local/hadoop
export HADOOP\_MAPRED\_HOME=/usr/local/hadoop
export HBASE\_HOME=/usr/local/hbase
export HIVE\_HOME=/usr/local/hive
#export ZOOCFGDIR=#如果读者配置了 Zookeeper,也需要在此配置 Zookeeper 的路径

#### 11.3.3 配置环境变量

使用 vim 编辑器打开~/. bashrc 文件,命令如下:

\$vim ~/.bashrc

在该文件开头加入如下代码:

export SQOOP\_HOME=/usr/local/sqoop
export PATH=\$PATH:\$SBT\_HOME/bin:\$SQOOP\_HOME/bin
export CLASSPATH=\$CLASSPATH:\$SQOOP\_HOME/lib

保存该文件,并退出 vim 编辑器。接下来执行如下命令使得环境变量立即生效:

\$source ~/.bashrc

# 11.3.4 添加 MySQL 驱动程序

首先需要安装 MySQL,之前在介绍第8章时,已经按照附录B完成了 MySQL 数据库的安装,这里不需要重复安装。

然后需要把 MySQL 驱动程序复制到 \$ SQOOP\_HOME/lib 目录下。之前在介绍第 8 章时,已经下载了 MySQL 驱动程序 mysql-connector-java-5. 1. 40. tar. gz,并且被放入到了 "/home/hadoop/下载"目录中。执行如下命令解压缩文件并复制到 Sqoop 安装目录下:

```
$cd ~/下载
$sudo tar - zxvf mysql-connector-java-5.1.40.tar.gz #解压 MySQL 驱动包
$#注意,如果第 8章已经解压缩了该文件,这里不用重复执行解压缩命令
$ls #这时就可以看到解压缩后得到的目录 mysql-connector-java-5.1.40
$cp ./mysql-
connector-java-5.1.40/mysql-connector-java-5.1.40-bin.jar /usr/local/sqoop/lib
```

# 11.3.5 测试与 MySQL 的连接

首先要确保 MySQL 服务已经启动,如果没有启动,执行下面命令启动:

```
$service mysql start
```

然后就可以测试 Sqoop 与 MySQL 之间的连接是否成功,命令如下:

```
$sqoop list-databases --connect jdbc:mysql://127.0.0.1:3306/ --username root -P
```

系统会提示输入密码,本书的 MySQL 数据库的 root 用户的密码是 hadoop。该命令执行结果如图 11-8 所示。

```
dblab@ubuntu:~/Downloads$ sqoop list-databases --connect jdbc:mysql://127.0.
0.1:3306/ --username hive -P
16/11/12 22:01:42 INFO sqoop.Sqoop: Running Sqoop version: 1.4.6
Enter password:
16/11/12 22:01:45 INFO manager.MySQLManager: Preparing to use a MySQL stream
Sat Nov 12 22:01:46 CST 2016 WARN: Establishing SSL connection without serve r's identity verification is not recommended. According to MySQL 5.5.45+, 5.
6.26+ and 5.7.6+ requirements SSL connection must be established by default
if explicit option isn't set. For compliance with existing applications not
using SSL the verifyServerCertificate property is set to 'false'. You need e
ither to explicitly disable SSL by setting useSSL=false, or set useSSL=true
and provide truststore for server certificate verification.
information_schema
hive
mysql
performance_schema
sys
test
dblab@ubuntu:~/Downloads$
```

图 11-8 sqoop list-databases 命令执行后的效果

如果能够看到 MySQL 数据库中的数据库列表,就表示 Sqoop 安装成功。例如,从图 11-8给出的信息中就可以看到在最后几行包含了如下的数据库列表:

```
Information_schema
dblab
hive
mysql
performance_schema
sys
test
```

# 11.4 实例: 编写 Spark 程序使用 Kafka 数据源

Spark Streaming 是用来进行流计算的组件。可以把 Kafka(或 Flume)作为数据源,让 Kafka(或 Flume)产生数据发送给 Spark Streaming 应用程序,Spark Streaming 应用程序再对接收到的数据进行实时处理,从而完成一个典型的流计算过程。这里仅以 Kafka 为例进行介绍,Spark 和 Flume 的组合使用也是类似的,这里不再赘述。

为了让 Spark Streaming 应用程序能够顺利使用 Kafka 数据源,在安装 Kafka 的时候,一定要注意,到 Kafka 官网下载安装文件时,一定要选择和自己计算机上已经安装的 Scala 版本号一致才可以。本书安装的 Spark 版本号是 1.6.2, Scala 版本号是 2.10,所以,一定要选择 Kafka 版本号是 2.10 开头的。例如,到 Kafka 官网中,可以下载安装文件 Kafka\_2.10-0.10.1.0,前面的 2.10 就是支持的 scala 版本号,后面的 0.10.1.0 是 Kafka 自身的版本号。正因为如此,在前面的第 11.2.2 节部分,下载的 Kafka 安装文件是 kafka\_2.10-0.10.1.0.tgz。

# 11.4.1 Kafka 准备工作

#### 1. 启动 Kafka

首先需要启动 Kafka, 登录 Linux 系统(本书统一使用 hadoop 用户登录), 打开一个终端,输入下面命令启动 Zookeeper 服务:

\$cd /usr/local/kafka

\$./bin/zookeeper-server-start.sh config/zookeeper.properties

注意:执行上面命令以后,终端窗口会返回一堆信息,然后就停住不动了,没有回到 shell 命令提示符状态,这时,千万不要错误地认为死机了,而是 Zookeeper 服务器启动了,正在处于服务状态。所以,千万不要关闭这个终端窗口,一旦关闭,Zookeeper 服务就停止了。

另外打开第二个终端,然后输入下面命令启动 Kafka 服务:

\$cd /usr/local/kafka

\$./bin/kafka-server-start.sh config/server.properties

同样,执行上面命令以后,终端窗口会返回一堆信息,然后就停住不动了,没有回到 shell 命令提示符状态,这时,千万不要错误地认为死机了,而是 Kafka 服务器启动了,正在 处于服务状态。所以,千万不要关闭这个终端窗口,一旦关闭,Kafka 服务就停止了。

当然,还有一种方式是采用下面加了 & 的命令:

\$cd /usr/local/kafka

\$bin/kafka-server-start.sh config/server.properties &

这样,Kafka 就会在后台运行,即使关闭了这个终端,Kafka 也会一直在后台运行。不过,这样做,有时候往往就忘记了还有 Kafka 在后台运行,所以,建议暂时不要用 &。

#### 2. 测试 Kafka 是否正常工作

下面先测试一下 Kafka 是否可以正常使用。请再另外打开第三个终端,然后输入下面命令创建一个自定义名称为 wordsendertest 的 topic:

\$cd /usr/local/kafka

\$./bin/kafka-topics.sh --create --zookeeper localhost:2181 --replicationfactor 1 --partitions 1 -- topic wordsendertest

#这个 topic 称为 wordsendertest,2181是 Zookeeper 默认的端口号,partition是 topic 里面的分区数,replication-factor是备份的数量,在 Kafka 集群中使用,这里单机版就不用备份了#可以用 list 列出所有创建的 topics,来查看上面创建的 topic是否存在

\$./bin/kafka-topics.sh --list --zookeeper localhost:2181

这个名称为 wordsendertest 的 topic,就是专门负责采集发送一些单词的。 下面用 producer 来产生一些数据,在当前终端内继续输入下面命令:

\$./bin/kafka-console-producer.sh --broker-list localhost:9092 --topic
wordsendertest

上面命令执行后,就可以在当前终端内用键盘输入一些英文单词,例如可以输入:

hello hadoop hello spark

这些单词就是数据源,这些单词会被 Kafka 捕捉到以后发送给消费者。现在可以启动一个消费者,来查看刚才 producer 产生的数据。另外打开第四个终端,输入下面命令:

\$cd /usr/local/kafka
\$./bin/kafka-console-consumer.sh --zookeeper localhost:2181 --topic
wordsender -- from-beginning

可以看到,屏幕上会显示出如下结果,也就是刚才在另外一个终端里面输入的内容:

hello hadoop hello spark

到这里,与 Kafka 相关的准备工作就顺利结束了。

注意: 所有这些终端窗口都不要关闭,要继续留着后面使用。

# 11.4.2 Spark 准备工作

#### 1. 添加相关 jar 包

Kafka 和 Flume 等高级输入源,需要依赖独立的库(jar 文件)。按照之前在第 9 章中已经安装好的 Spark 版本,这些 jar 包都不在里面,为了证明这一点,现在可以测试一下。请打开一个新的终端,然后启动 spark-shell,命令如下:

\$cd /usr/local/spark
\$./bin/spark-shell

启动成功后,在 spark-shell 中执行下面 import 语句:

scala>import org.apache.spark.streaming.kafka.\_
<console>:25: error: object kafka is not a member of package org.apache.spark.streaming
import org.apache.spark.streaming.kafka.\_

可以看到,马上会报错,因为找不到相关的 jar 包。所以,需要下载 spark-streaming-kafka\_2.10. jar。

在 Linux 系统中打开浏览器,访问 Spark 官网(http://mvnrepository.com/artifact/org.apache.spark/spark-streaming-kafka\_2.10),里面有提供 spark-streaming-kafka\_2.10.jar 文件的下载,其中,2.10表示 Scala 的版本。这个下载页面会列出 spark-streaming-kafka\_2.10.jar 的很多版本,这里选择 1.6.2版本(因为本书安装的 Spark 版本是 1.6.2),可以单击 1.6.2版本的按钮,进入 spark-streaming-kafka\_2.10-1.6.2.jar 的下载页面,单击下载。下载后的文件会被默认保存在当前 Linux 登录用户的下载目录下,本书统一使用hadoop 用户名登录 Linux 系统,所以,文件下载后会被保存到"/home/hadoop/下载"目录下面。

或者也可以访问本书官网的"下载专区",在"软件"目录下下载 spark-streaming-kafka\_2.10-1.6.2.jar 文件。

现在需要把这个文件复制到 Spark 目录的 lib 目录下。请新打开一个终端,输入如下命令:

\$cd /usr/local/spark/lib

\$mkdir kafka

\$cd ~

\$cd下载

\$cp ./spark-streaming-kafka 2.10-1.6.2.jar /usr/local/spark/lib/kafka

这样,就把 spark-streaming-kafka\_2.10-1.6.2. jar 文件复制到了/usr/local/spark/lib/kafka 目录下。

现在还需要在 Linux 系统中打开浏览器,访问网址 https://www.versioneye.com/

java/org. apache. spark: spark-streaming\_2. 10/1. 6. 2,下载另外一个文件 spark-streaming\_2. 10-1. 6. 2. jar;或者也可以访问本书官网的"下载专区",在"软件"目录下下载 spark-streaming\_2. 10-1. 6. 2. jar 文件。其中,2. 10 是 Scala 版本号,1. 6. 2 是 Spark 版本号。

spark-streaming\_2.10-1.6.1.jar下载成功以后,默认会被放到当前 Linux 登录用户的下载目录下,本书统一使用 hadoop 用户名登录 Linux 系统,所以,文件下载后会被保存到 "/home/hadoop/下载"目录下面。现在需要把这个文件复制到 Spark 目录的 lib 目录下。新打开一个终端,输入下面命令:

```
$cd /usr/local/spark/lib
$cd ~
$cd 下载
$cp ./spark-streaming_2.10-1.6.1.jar /usr/local/spark/lib/kafka
```

还要继续把 Kafka 安装目录的 lib 目录下的所有 jar 文件复制到/usr/local/spark/lib/kafka 目录下,在终端中执行下面的命令:

```
$cd /usr/local/kafka/libs
$ls
$cp ./* /usr/local/spark/lib/kafka
```

全部复制过来以后,有些 jar 包会和 Spark 中已经有的 jar 包发生冲突,程序一运行就会出现一堆错误,因此,需要把下面这些 jar 包删除掉,这样才不会出现错误,命令如下:

```
$cd /usr/local/kafka/libs
$ls
$rm log4j *
$rm jackson *
```

#### 2. 修改配置文件

现在需要配置/usr/local/spark/conf 目录下的 spark-env. sh 文件,让 Spark 能够在启动的时候找到 spark-streaming-kafka\_2.10-1.6.2. jar 等 5 个 jar 文件。使用 vim 编辑器打开 spark-env. sh 文件,命令如下:

```
$cd /usr/local/spark/conf
$vim spark-env.sh
```

因为这个文件之前已经反复修改过,目前里面的前面几行的内容应该如下:

```
export SPARK_CLASSPATH=$SPARK_CLASSPATH:/usr/local/spark/lib/hbase/*
export SPARK_DIST_CLASSPATH=$(/usr/local/hadoop/bin/hadoop classpath)
```

只要简单修改一下,把/usr/local/spark/lib/kafka/\*增加进去,修改后的内容如下:

export
SPARK\_CLASSPATH = \$SPARK\_CLASSPATH:/usr/local/spark/lib/hbase/\*:/usr/local/spark/lib/
kafka/\*
export SPARK DIST CLASSPATH=\$(/usr/local/hadoop/bin/hadoop classpath)

保存该文件后,退出 vim 编辑器。

#### 3. 启动 spark-shell

执行如下命令启动 spark-shell:

\$cd /usr/local/spark
\$./bin/spark-shell

启动成功后,再次执行如下命令:

scala>import org.apache.spark.streaming.kafka.\_
//会显示下面的信息
import org.apache.spark.streaming.kafka.\_

也就是说,现在使用 import 语句,不会像之前那样出现错误信息了,说明已经导入成功。至此,就已经准备好了 Spark 环境,它可以支持 kafka 相关编程了。

# 11.4.3 编写 Spark 程序使用 Kafka 数据源

1. 编写生产者(producer)程序

打开一个终端,然后执行如下命令创建代码目录和代码文件:

\$cd /usr/local/spark/mycode
\$mkdir kafka
\$cd kafka
\$mkdir -p src/main/scala
\$cd src/main/scala
\$vim KafkaWordProducer.scala

这里使用 vim 编辑器新建 KafkaWordProducer. scala,它是用来产生一系列字符串的程序,会产生随机的整数序列,每个整数被当成一个单词,提供给 KafkaWordCount 程序去进行词频统计。请在 KafkaWordProducer. scala 中输入以下代码:

import java.util.HashMap
import org.apache.kafka.clients.producer.{ProducerConfig, KafkaProducer, ProducerRecord}
import org.apache.spark.streaming.\_
import org.apache.spark.streaming.kafka.\_

```
import org.apache.spark.SparkConf
object KafkaWordProducer {
  def main(args: Array[String]) {
    if (args.length<4) {
      System.err.println("Usage: KafkaWordCountProducer<metadataBrokerList>
      <topic>"+ "<messagesPerSec><wordsPerMessage>")
      System.exit(1)
    val Array (brokers, topic, messagesPerSec, wordsPerMessage) = args
    //Zookeeper connection properties
    val props=new HashMap[String, Object]()
    props.put(ProducerConfig.BOOTSTRAP SERVERS CONFIG, brokers)
   props.put (ProducerConfig.VALUE SERIALIZER CLASS CONFIG,
      "org.apache.kafka.common.serialization.StringSerializer")
   props.put (ProducerConfig.KEY_SERIALIZER_CLASS_CONFIG,
      "org.apache.kafka.common.serialization.StringSerializer")
    val producer=new KafkaProducer[String, String] (props)
```

保存后退出 vim 编辑器。上述代码也可以直接到本书官网"下载专区"下载,位于"代码"目录的"第 11 章"子目录下,文件名是 KafkaWordProducer. scala。

#### 2. 编写消费者(consumer)程序

继续在当前目录下创建 KafkaWordCount. scala 代码文件,命令如下:

```
$vim KafkaWordCount.scala
```

KafkaWordCount. scala 用于单词词频统计,它会把 KafkaWordProducer 发送过来的单词进行词频统计,代码内容如下:

```
import org.apache.spark._
import org.apache.spark.SparkConf
import org.apache.spark.streaming._
import org.apache.spark.streaming.kafka._
import org.apache.spark.streaming.StreamingContext._
import org.apache.spark.streaming.kafka.KafkaUtils
object KafkaWordCount{
def main(args:Array[String]){
StreamingExamples.setStreamingLogLevels()
val sc=new SparkConf().setAppName("KafkaWordCount").setMaster("local[2]")
val ssc=new StreamingContext(sc,Seconds(10))
ssc.checkpoint("file:///usr/local/spark/mycode/kafka/checkpoint")
//设置检查点,如果存放在 HDFS 上面,则写成类似 ssc.checkpoint("/user/hadoop/checkpoint")
这种形式,但是,要启动 hadoop
```

```
val zkQuorum="localhost:2181" //Zookeeper 服务器地址
                            //topic 所在的 group,可以设置为自己想要的名称,例如不用 1,
val group="1"
                             而是 val group="test-consumer-group"
                           //topics的名称
val topics="wordsender"
                           //每个 topic 的分区数
val numThreads=1
val topicMap=topics.split(",").map(( ,numThreads.toInt)).toMap
val lineMap=KafkaUtils.createStream(ssc,zkQuorum,group,topicMap)
val lines=lineMap.map(_._2)
val words=lines.flatMap(_.split(" "))
val pair=words.map(x=>(x,1))
val wordCounts=pair.reduceByKeyAndWindow(_+_,_-_,Minutes(2),Seconds(10),2) //这行代码
的含义在下一节的窗口转换操作中会有介绍
wordCounts.print
ssc.start
ssc.awaitTermination
```

保存后退出 vim 编辑器。上述代码也可以直接到本书官网"下载专区"下载,位于"代码"目录的"第 11 章"子目录下,文件名是 KafkaWordCount. scala。

#### 3. 编写日志格式设置程序

继续在当前目录下创建 Streaming Examples. scala 代码文件,命令如下:

```
$vim StreamingExamples.scala
```

下面是 Streaming Examples. scala 的代码,这段代码的功能是用于设置 log4j 的日志格式:

```
import org.apache.spark.Logging
import org.apache.log4j.{Level, Logger}
/** Utility functions for Spark Streaming examples * /
object StreamingExamples extends Logging {
    /** Set reasonable logging levels for streaming if the user has not configured log4j. * /
    def setStreamingLogLevels() {
        val log4jInitialized=Logger.getRootLogger.getAllAppenders.hasMoreElements
        if(!log4jInitialized) {
            //We first log something to initialize Spark's default logging, then we override the
            //logging level
```

```
logInfo("Setting log level to [WARN] for streaming example."+
        " To override add a custom log4j.properties to the classpath.")
        Logger.getRootLogger.setLevel(Level.WARN)
    }
}
```

上述代码也可以直接到本书官网"下载专区"下载,位于"代码"目录的"第 11 章"子目录下,文件名是 Streaming Examples. scala。

#### 4. 编译打包程序

经过前面的步骤,在/usr/local/spark/mycode/kafka/src/main/scala 目录下,就有了如下3个代码文件:

```
KafkaWordProducer.scala
KafkaWordCount.scala
StreamingExamples.scala
```

#### 执行下面的命令:

```
$cd /usr/local/spark/mycode/kafka/
$vim simple.sbt
```

在 simple. sbt 中输入以下代码:

```
name := "Simple Project"
version := "1.0"
scalaVersion := "2.10.5"
libraryDependencies+= "org.apache.spark" %%"spark-core" %"1.6.2"
libraryDependencies+= "org.apache.spark" %"spark-streaming_2.10" %"1.6.2"
libraryDependencies+= "org.apache.spark" %"spark-streaming-kafka_2.10" %"1.6.2"
```

保存文件退出 vim 编辑器。上述代码也可以直接到本书官网"下载专区"下载,位于 "代码"目录的"第 11 章"子目录下,文件名是 simple. sbt。

执行下面命令,进行打包编译:

```
$cd /usr/local/spark/mycode/kafka/
$/usr/local/sbt/sbt package
```

打包成功后,就可以执行程序测试效果了。

#### 5. 运行程序

首先启动 Hadoop,因为如果前面 KafkaWordCount. scala 代码文件中采用了 ssc.

checkpoint("/user/hadoop/checkpoint")这种形式,这时的检查点是被写入 HDFS,因此需要启动 Hadoop。启动 Hadoop的命令如下:

```
$cd /usr/local/hadoop
$./sbin/start-dfs.sh
```

启动 Hadoop 成功以后,就可以测试刚才生成的词频统计程序了。

要注意,之前已经启动了 Zookeeper 服务,启动了 Kafka 服务,因为之前那些终端窗口都没有关闭,所以,这些服务一直都在运行。如果不小心关闭了之前的终端窗口,那就参照前面的内容,再次启动 Zookeeper 服务,启动 Kafka 服务。

打开一个终端,执行如下命令,运行 KafkaWordProducer 程序,生成一些单词(是一堆整数形式的单词):

```
$cd /usr/local/spark
$/usr/local/spark/bin/spark-submit --class "KafkaWordProducer"
/usr/local/spark/mycode/kafka/target/scala-2.10/simple-project_2.10-1.0.jar localhost:
9092 wordsender 3 5
```

注意:上面命令中,localhost:9092 wordsender 3 5 是提供给 KafkaWordProducer 程序的 4 个输入参数,第 1 个参数 localhost:9092 是 Kafka 的 broker 的地址,第 2 个参数 wordsender 是 topic 的名称,在 KafkaWordCount. scala 代码中已经把 topic 名称固定为 wordsender,所以,KafkaWordCount 程序只能接收名称为 wordsender 的 topic。第 3 个参数 3 表示每秒发送 3 条消息,第 4 个参数 5 表示每条消息包含 5 个单词(实际上就是 5 个整数)。

执行上面命令后,屏幕上会不断滚动出现新的单词,如下:

```
3 3 6 3 4
94081
0 3 3 9 3
08409
87295
26485
09609
40081
18374
40657
39150
93967
18743
95626
48868
00337
```

这个终端窗口就放在这里,千万不要关闭,让它一直不断发送单词;然后新打开一个终端,执行下面命令,运行 KafkaWordCount 程序,执行词频统计:

```
$cd /usr/local/spark
$/usr/local/spark/bin/spark-submit --class "KafkaWordCount"
/usr/local/spark/mycode/kafka/target/scala-2.10/simple-project_2.10-1.
0.jar
```

运行上面命令以后,就启动了词频统计功能,屏幕上就会显示如下信息:

```
SLF4J: Class path contains multiple SLF4J bindings.
SLF4J: Found binding in [jar:file:/usr/local/spark/lib/kafka/slf4j-log4j12-1.7.21.jar!/
org/slf4j/impl/StaticLoggerBinder.class]
SLF4J: Found binding in [jar: file:/usr/local/hadoop/share/hadoop/common/lib/slf4j -
log4j12-1.7.10.jar!/org/slf4j/impl/StaticLoggerBinder.class]
SLF4J: See http://www.slf4j.org/codes.html# multiple bindings for an explanation.
SLF4J: Actual binding is of type [org.slf4j.impl.Log4jLoggerFactory]
Time: 1479789000000 ms
(4, 16)
(8, 14)
(6, 15)
(0, 10)
(2,9)
(7,17)
 (5, 14)
(9, 9)
(3, 8)
(1,8)
```

这些信息说明, Spark Streaming 程序顺利接收到了 Kafka 发来的单词信息,并进行词 频统计得到结果。

# 11.5 本章小结

日志采集工具 Flume 和 Kafka 经常用在 Hadoop 和 Spark 生态系统中,用来进行日志信息的实时采集。本章首先介绍了日志采集工具 Flume 和 Kafka 的安装和使用方法,并给出了几个实例演示工具的具体用法。

Sqoop 提供了在 Hadoop 和关系数据库之间进行数据相互导入导出操作的功能,大大提高了数据交换的效率,不需要手工编写大量代码对数据进行操作。本章内容介绍了

Sqoop 的安装和使用方法,在后面第 12 章中,会继续使用 Sqoop 工具来实现 MySQL 和 HBase、Hive 之间的数据迁移。

本章最后详细介绍了如何编写 Spark Streaming 应用程序来"消费"Kafka 的数据源,通过这个实例,可以从总体上了解 Spark 和 Kafka 等工具之间的组合使用方法。

# 第12章

# 大数据课程综合实验案例

本案例涉及数据预处理、存储、查询和可视化分析等数据处理全流程所涉及的各种典型操作,涵盖 Linux、MySQL、Hadoop、HBase、Hive、Sqoop、R、Eclipse 等系统和软件的安装和使用方法。本案例适合高校大数据教学,可以作为学习大数据课程后的综合实践案例。通过本案例,有助于读者综合运用大数据课程知识和各种工具软件,实现数据全流程操作。

# 12.1 案例简介

本节介绍案例的目的、适用对象、时间安排、预备知识、硬件要求、软件工具、数据集和案例任务等内容。

# 12.1.1 案例目的

- (1) 熟悉 Linux 系统、MySQL、Hadoop、HBase、Hive、Sqoop、R、Eclipse 等系统和软件的安装和使用。
  - (2) 了解大数据处理的基本流程。
  - (3) 熟悉数据预处理方法。
  - (4) 熟悉在不同类型数据库之间进行数据相互导入和导出。
  - (5) 熟悉使用 R 语言进行可视化分析。
  - (6) 熟悉使用 Eclipse 编写 Java 程序操作 HBase 数据库。

# 12.1.2 适用对象

- (1) 高校(高职)教师、学生。
- (2) 大数据学习者。

# 12.1.3 时间安排

本案例可以作为大数据入门级课程结束后的"大作业",或者可以作为学生暑期或寒假大数据实习实践基础案例,建议在一周左右完成本案例。

# 12.1.4 预备知识

需要案例使用者,已经学习过大数据相关课程(例如入门级课程"大数据技术原理与应用"),了解大数据相关技术的基本概念与原理,了解 Windows 操作系统、Linux 操作系统、

大数据处理架构 Hadoop 的关键技术及其基本原理、列族数据库 HBase 概念及其原理、数据仓库概念与原理、关系型数据库概念与原理、R语言概念与应用等。

不过,由于本案例提供了全部操作细节,包括每个命令和运行结果,所以,即使没有相关背景知识,也可以按照操作说明顺利完成全部实验。

# 12.1.5 硬件要求

本案例可以在单机上完成,也可以在集群环境下完成。单机上完成本案例实验时,建议 计算机硬件配置为:500GB以上硬盘,8GB以上内存。

# 12.1.6 软件工具

本案例所涉及的系统及软件包括 Linux 系统、MySQL、Hadoop、HBase、Hive、Sqoop、R、Eclipse 等(见图 12-1)。

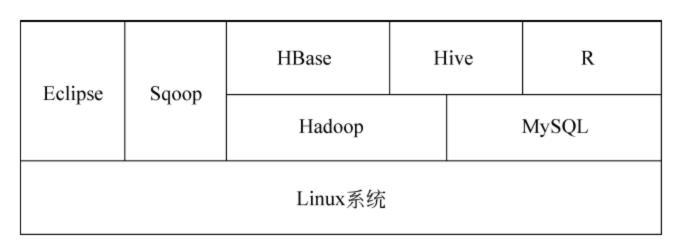


图 12-1 本案例所涉及的系统及软件

相关软件的版本建议如下:

- (1) Linux: Ubuntu 16.04.
- (2) MySQL: 5.7.16.
- (3) Hadoop: 2.7.1.
- (4) HBase: 1.1.5.
- (5) Hive: 1.2.1.
- (6) Sqoop: 1.4.6.
- (7) R:3.2.3.
- (8) Eclipse: 3.8.

## 12.1.7 数据集

网站用户购物行为数据集,包括2000万条记录。

## 12.1.8 案例任务

图 12-2 展示了案例全流程的各个环节,具体而言,本案例需要完成以下实验任务。

- (1) 安装 Linux 操作系统。
- (2) 安装关系型数据库 MySQL。
- (3) 安装大数据处理框架 Hadoop。

- (4) 安装列族数据库 HBase。
- (5) 安装数据仓库 Hive。
- (6) 安装 Sqoop。
- (7) 安装 R。
- (8) 安装 Eclipse。
- (9) 对文本文件形式的原始数据集进行预处理。
- (10) 把文本文件的数据集导入到数据仓库 Hive 中。
- (11) 对数据仓库 Hive 中的数据进行查询分析。
- (12) 使用 Sqoop 将数据从 Hive 导入 MySQL。
- (13) 使用 Sqoop 将数据从 MySQL 导入 HBase。
- (14) 使用 HBase Java API 把数据从本地导入到 HBase 中。
- (15) 使用 R 对 MySQL 中的数据进行可视化分析。

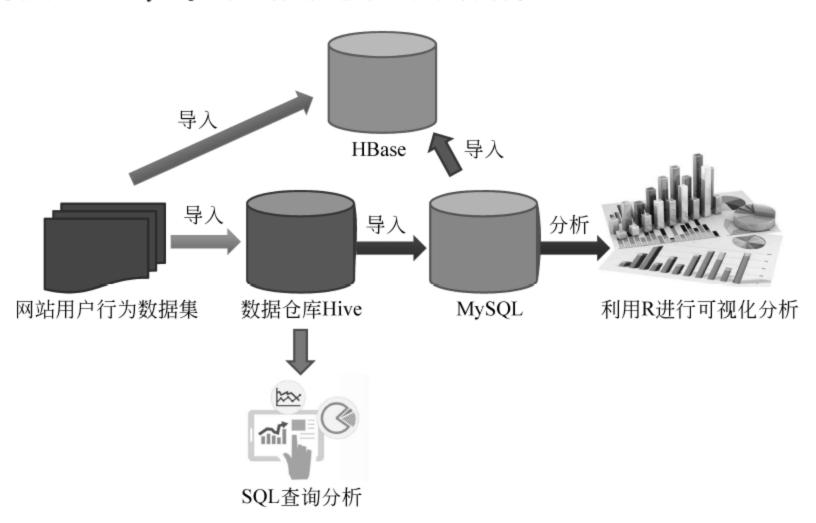


图 12-2 案例任务概览图

# 12.2 实验环境搭建

为了顺利完成本案例各项实验,需要完成以下系统和软件的安装。

- (1) 安装 Linux 系统: 如果未安装,参照第2章的相关内容,完成 Linux 系统的安装。
- (2) 安装 Hadoop: 如果未安装,参照第3章的相关内容,完成 Hadoop 的安装。
- (3) 安装 MySQL: 如果未安装,参照附录 B的相关内容,完成 MySQL 的安装。
- (4) 安装 HBase: 如果未安装,参照第5章的相关内容,完成 HBase 的安装。
- (5) 安装 Hive: 如果未安装,参照第8章的相关内容,完成 Hive 的安装。
- (6) 安装 Sqoop: 如果未安装,参照第 11 章的内容,完成 Sqoop 的安装。
- (7) 安装 Eclipse: 如果未安装,参照第2章的相关内容,在 Linux 系统安装 Eclipse。

# 12.3 实验步骤概述

本案例共包含 4 个实验步骤。

- (1) 本地数据集上传到数据仓库 Hive。
- (2) Hive 数据分析。
- (3) Hive、MySQL、HBase 数据互导。
- (4) 利用 R 进行数据可视化分析。

下面 4 个表(表 12-1~表 12-4)分别给出了每个实验步骤所需的知识储备、训练技能和任务清单。

± 10 1	十小米伊伊	上伏对北提人士	***
表 12-1	4 11 数 16 集	上传到数据仓库	Hive

项 目	解释
所需知识储备	Linux 系统基本命令、Hadoop 项目结构、分布式文件系统(HDFS)的概念及其基本原理、数据仓库的概念及其基本原理、数据仓库 Hive 的概念及其基本原理
训练技能	Hadoop 的安装与基本操作、HDFS 的基本操作、Linux 的安装与基本操作、数据仓库 Hive 的安装与基本操作、基本的数据预处理方法
任务清单	安装 Linux 系统、数据集下载与查看、数据集预处理、把数据集导入分布式文件系统 HDFS 中、在数据仓库 Hive 上创建数据库

表 12-2 Hive 数据分析

项 目	解 释
所需知识储备	数据仓库 Hive 的概念及其基本原理、SQL 语句、数据库查询分析
训练技能	数据仓库 Hive 的基本操作、创建数据库和表、使用 SQL 语句进行查询分析
任务清单	启动 Hadoop 和 Hive、创建数据库和表、简单查询分析、查询条数统计分析、关键字条件查询分析、根据用户行为分析、用户实时查询分析

#### 表 12-3 Hive、MySQL、HBase 数据互导

项 目	解释
所需知识储备	数据仓库 Hive 的概念与基本原理、关系数据库的概念与基本原理、SQL 语句、列族数据库 HBase 的概念与基本原理
训练技能	数据仓库 Hive 的基本操作、关系数据库 MySQL 的基本操作、Sqoop 工具的使用方法、HBase API 的 Java 编程、Eclipse 开发工具的使用方法
任务清单	Hive 预操作、使用 Sqoop 将数据从 Hive 导入 MySQL、使用 Sqoop 将数据从 MySQL 导入 HBase、使用 HBase Java API 把数据从本地导入到 HBase 中

#### 表 12-4 利用 R 进行数据可视化分析

项 目	解释
所需知识储备	数据可视化、R 语言
训练技能	利用 R 语言对 MySQL 数据库中的数据进行数据可视化分析、R 的安装、相关可视化依赖包的安装与使用、各种可视化图表的生成方法
任务清单	安装 R 语言包、安装可视化依赖包、柱状图可视化分析、散点图可视化分析、地图可视 化分析

# 12.4 本地数据集上传到数据仓库 Hive

本节介绍实验数据集的下载、数据集的预处理和导入数据库等。

# 12.4.1 实验数据集的下载

本案例采用的数据集为 user. zip,它包含一个大规模数据集 raw\_user. csv(包含 2000 万条记录)和一个小数据集 small\_user. csv(只包含 30 万条记录)。小数据集 small\_user. csv 是从大规模数据集 raw\_user. csv 中抽取的一小部分数据。之所以抽取出一少部分记录单独构成一个小数据集,是因为在第一遍跑通整个实验流程时,会遇到各种错误、各种问题, 先用小数据集测试,可以大量节约程序运行时间。等到第一次完整实验流程都顺利跑通以后,可以最后用大规模数据集进行最后的测试。可以采用下面两种方法中的其中一种方法完成实验数据集的下载。

- (1) 在 Windows 系统中,访问本书官网的"下载专区",找到"数据集"目录,把该目录下的 user. zip 文件下载到本地;然后使用 FTP 方式(可以参照第 2 章中介绍的 FTP 使用方法),把 Windows 系统中的 user. zip 文件上传到 Linux 系统的"/home/hadoop/下载/"目录下。
- (2) 登录 Linux 系统(本书统一采用 hadoop 用户登录),并在 Linux 系统中打开浏览器 (一般都是火狐浏览器);然后在 Linux 系统的浏览器中访问本书官网的"下载专区",找到"数据集"目录,把该目录下的 user. zip 文件下载到本地。如果在下载时没有修改文件保存路径,火狐浏览器会默认把文件保存在当前用户的下载目录下,因为本书是采用 hadoop 用户名登录了 Linux 系统,所以,下载后的文件会被浏览器默认保存到"/home/hadoop/下载/"目录下面。

通过上面的任意一种方法,都可以顺利把数据集 user. zip 文件下载到 Linux 系统的 "/home/hadoop/下载/"目录下面。现在,在 Linux 系统中打开一个终端(可以使用快捷键 Ctrl+Alt+T),执行下面命令(Shell 命令):

\$cd /home/hadoop/下载

\$ls

通过上面命令,进入到 user. zip 文件所在的目录,并且可以看到有个 user. zip 文件。

注意: 如果把 user. zip 下载到其他目录,进入到你自己的存放 user. zip 的目录。

下面需要把 user. zip 进行解压缩,首先建立一个用于运行本案例的目录 bigdatacase,执行以下命令:

\$cd /usr/local

\$ls

\$sudo mkdir bigdatacase

#这里会提示你输入当前用户(本书是 hadoop用户名)的密码

#下面给 hadoop 用户赋予针对 bigdatacase 目录的各种操作权限

```
$cd bigdatacase

#下面创建一个 dataset 目录,用于保存数据集

$mkdir dataset

#下面就可以解压缩 user.zip文件

$cd ~ //表示进入 hadoop用户的目录
```

\$sudo chown -R hadoop:hadoop ./bigdatacase

THE

\$cd 下载

\$ls

\$unzip user.zip - d /usr/local/bigdatacase/dataset

\$cd /usr/local/bigdatacase/dataset

\$ls

现在就可以看到在 dataset 目录下有两个文件: raw\_user. csv 和 small\_user. csv。执行下面命令取出前面 5 条记录看一下:

\$head - 5 raw\_user.csv

可以看到,前5行记录如下:

```
user_id,item_id,behavior_type,user_geohash,item_category,time 10001082,285259775,1,971k14c,4076,2014-12-08 18 10001082,4368907,1,,5503,2014-12-12 12 10001082,4368907,1,,5503,2014-12-12 12 10001082,53616768,1,,9762,2014-12-02 15
```

可以看出,每行记录都包含5个字段,数据集中的字段及其含义如下。

- (1) user\_id(用户 id)。
- (2) item\_id(商品 id)。
- (3) behaviour\_type(包括浏览、收藏、加购物车、购买,对应取值分别是1、2、3、4)。
- (4) user\_geohash(用户地理位置哈希值,有些记录中没有这个字段值,所以后面会用脚本做数据预处理时把这个字段全部删除)。
  - (5) item\_category(商品分类)。
  - (6) time(该记录产生时间)。

# 12.4.2 数据集的预处理

1. 删除文件第一行记录(即字段名称)

raw\_user 和 small\_user 中的第一行都是字段名称,把文件中的数据导入到数据仓库 Hive 中时,不需要第一行字段名称,因此,在做数据预处理时,需要删除第一行,执行以下命令(Shell 命令):

```
$cd /usr/local/bigdatacase/dataset
#下面删除 raw_user 中的第一行
$sed - i 'ld' raw_user
#上面的 ld表示删除第一行,同理,3d表示删除第 3 行,nd表示删除第 n 行
#下面删除 small_user 中的第一行
$sed - i 'ld' small_user
#下面再用 head命令去查看文件的前 5 行记录,这时看不到字段名称这一行了
$head - 5 raw_user.csv
$head - 5 small_user.csv
```

接下来的操作中,都是用 small\_user. csv 这个小数据集进行操作,这样可以节省时间。 等所有流程都跑通以后,就可以使用大数据集 raw\_user. csv 去测试一遍整个案例。

#### 2. 对字段进行预处理

下面对数据集进行预处理,包括为每行记录增加一个 id 字段(让记录具有唯一性)、增加一个省份字段(用来后续进行可视化分析),并且丢弃 user\_geohash 字段(后面分析不需要这个字段)。

下面要建一个脚本文件 pre\_deal. sh,把这个脚本文件放在 dataset 目录下,和数据集 small\_user. csv 放在同一个目录下:

```
$cd /usr/local/bigdatacase/dataset
$vim pre_deal.sh
```

上面使用 vim 编辑器新建了一个 pre\_deal. sh 脚本文件,在这个脚本文件中加入下面代码:

```
#!/bin/bash
#下面设置输入文件,把用户执行 pre_deal.sh命令时提供的第一个参数作为输入文件名称
infile=$1
#下面设置输出文件,把用户执行 pre_deal.sh命令时提供的第二个参数作为输出文件名称
outfile=$2
#注意,最后的$infile>$outfile必须跟在}和'这两个字符的后面
awk-F"," 'BEGIN{
srand();
id=0;
Province[0]="山东";Province[1]="山西";Province[2]="河南";Province[3]=
"河北";Province[4]="陕西";Province[5]="内蒙古";Province[6]="上海市";
Province[7]="北京市";Province[8]="重庆市";Province[9]="天津市";Province[10]="福建";Province[11]="广东";Province[12]="广西";Province[13]="云南";
Province[14]="浙江";Province[15]="贵州";Province[16]="新疆";Province[17]="西藏";
Province[18]="江西";Province[19]="湖南";Province[20]="湖北";
```

```
Province[21]="黑龙江"; Province[22]="吉林"; Province[23]="辽宁"; Province[24]="江苏"; Province[25]="甘肃"; Province[26]="青海"; Province[27]="四川"; Province[28]="安徽"; Province[29]="宁夏"; Province[30]="海南"; Province[31]="香港"; Province[32]="澳门"; Province[33]="台湾"; did=id+1; value=int(rand() * 34); print id"\t"$1"\t"$2"\t"$3"\t"$5"\t"substr($6,1,10)"\t"Province[value] }' $infile>$outfile
```

上述代码也可以直接到本书官网"下载专区"下载,位于"代码"目录的"第 12 章"子目录下,文件名是 pre\_deal. sh。为了更好理解上面的代码,这里给出 awk 命令的基本形式:

```
awk-F","'处理逻辑'$infile>$outfile
```

使用 awk 可以逐行读取输入文件,并对逐行进行相应操作。其中,-F 参数用于指出每行记录的不同字段之间用什么字符进行分隔,这里是用逗号进行分隔。处理逻辑代码需要用两个英文单引号引起来。\$infile 是输入文件的名称,这里会输入 raw\_user.csv,\$outfile 表示处理结束后输出的文件名称,后面会使用 user\_table.txt 作为输出文件名称。

在上面的 pre\_deal. sh 代码的处理逻辑部分, srand()用于生成随机数的种子, id 是为数据集新增的一个字段, 它是一个自增类型, 每条记录增加 1, 这样可以保证每条记录具有唯一性。这里再为数据集新增一个省份字段, 用来进行后面的数据可视化分析。为了给每条记录增加一个省份字段的值, 这里首先用 Province[]数组用来保存全国各个省份信息, 然后, 在遍历数据集 raw\_user. csv 的时候, 每当遍历到其中一条记录, 就使用 value=int(rand()\*34)语句随机生成一个0~33的整数, 作为 Province 省份值; 然后从 Province[]数组当中获取该省份值对应的省份名称, 增加到该条记录中。

substr(\$6,1,10)这个语句是为了截取时间字段 time 的年、月、日,方便后续存储为date 格式。awk 每次遍历到一条记录时,每条记录包含 6 个字段,其中,第 6 个字段是时间字段。substr(\$6,1,10)语句就表示获取第 6 个字段的值,截取前 10 个字符,第 6 个字段是数似"2014-12-08 18"这样的字符串(也就是表示 2014年12月8日18时),substr(\$6,1,10)截取后,就丢弃了小时,只保留了年、月、日。

另外,代码中还包含下面这条语句:

```
print id"\t"$1"\t"$2"\t"$3"\t"$5"\t"substr($6,1,10)"\t"Province[value]
```

在这行语句中,丢弃了每行记录的第4个字段,所以,没有出现\$4。生成后的文件是\t 进行分隔,这样,后续去查看数据的时候,屏幕上的显示效果会更加整齐美观,每个字段在排 版的时候会对齐显示;相反,如果用逗号分隔,显示效果会比较乱。

最后保存 pre\_deal. sh 代码文件,退出 vim 编辑器。

执行 pre\_deal. sh 脚本文件,对 small\_user. csv 进行数据预处理,命令如下:

```
$cd /usr/local/bigdatacase/dataset
$bash ./pre_deal.sh small_user.csv user_table.txt
```

可以查看生成的 user\_table. txt,但是,不要直接打开,因为文件过大,直接打开会出错,可以使用 head 命令查看前 10 行数据:

```
$head - 10 user_table.txt
```

执行上面命令以后,可以得到如下结果:

```
2014-12-08 广东
              285259775
                            4076
   10001082
                        1
1
              4368907
                            5503
                                    2014-12-12 河南
   10001082
                         1
                                    2014-12-12 甘肃
              4368907
                            5503
   10001082
                                    2014-12-02 北京市
   10001082
              53616768
                            9762
                         1
                                    2014-12-12 安徽
                            5232
   10001082
              151466952
                        1
                                    2014-12-02 北京市
                            9762
   10001082
              53616768
                                    2014-12-12 山东
   10001082
              290088061
                         1
                            5503
                                    2014-12-12 福建
   10001082
              298397524
                        1
                            10894
                                    2014-12-12 湖南
   10001082
              32104252
                            6513
                                    2014-12-12 山东
10 10001082
              323339743
                            10894
                        1
```

# 12.4.3 导入数据库

下面把 user\_table. txt 中的数据导入到数据仓库 Hive 中。为了完成这个操作,首先需要把 user\_table. txt 上传到分布式文件系统 HDFS 中;然后在 Hive 中创建一个外部表,完成数据的导入。

#### 1. 启动 HDFS

HDFS是 Hadoop 的核心组件,因此,需要使用 HDFS,必须首先安装 Hadoop。这里假设已经安装了 Hadoop,本书使用的是 Hadoop2.7.1 版本,安装目录是/usr/local/hadoop。

下面登录 Linux 系统,打开一个终端,执行下面命令启动 Hadoop:

```
$cd /usr/local/hadoop
$./sbin/start-all.sh
```

然后执行 jps 命令看一下当前运行的进程:

```
$jps
```

如果出现下面这些进程,说明 Hadoop 已经启动成功:

3765 NodeManager

3639 ResourceManager

3800 Jps

3261 DataNode

3134 NameNode

3471 SecondaryNameNode

#### 2. 把 user\_table.txt 上传到 HDFS 中

现在需要把 Linux 本地文件系统中的 user\_table. txt 上传到分布式文件系统 HDFS中,并存放在 HDFS中的/bigdatacase/dataset 目录下。

首先需要在 HDFS 的根目录下面创建一个新的目录 bigdatacase,并在这个目录下创建一个子目录 dataset,具体命令如下:

\$cd /usr/local/hadoop

\$./bin/hdfs dfs -mkdir -p /bigdatacase/dataset

然后把 Linux 本地文件系统中的 user\_table. txt 上传到分布式文件系统 HDFS 的 /bigdatacase/dataset 目录下,命令如下:

\$cd /usr/local/hadoop

\$./bin/hdfs dfs - put /usr/local/bigdatacase/dataset/user\_table.txt

/bigdatacase/dataset

现在可以查看一下 HDFS 中的 user\_table. txt 的前 10 条记录,命令如下:

\$cd /usr/local/hadoop

\$./bin/hdfs dfs - cat /bigdatacase/dataset/user\_table.txt | head - 10

#### 3. 在 Hive 上创建数据库

这里假设已经完成了 Hive 的安装,并且使用 MySQL 数据库保存 Hive 的元数据。本书安装的是 Hive2.1.0 版本,安装目录是/usr/local/hive。

下面在 Linux 系统中再新建一个终端(可以在刚才已经建好的终端界面的左上角,单击"终端"菜单,在弹出的子菜单中选择"新建终端")。因为需要借助于 MySQL 保存 Hive 的元数据,所以,先启动 MySQL 数据库,可以在终端中输入如下命令:

\$service mysql start

#可以在 Linux 的任何目录下执行该命令

由于 Hive 是基于 Hadoop 的数据仓库,使用 HiveQL 语言撰写的查询语句,最终都会被 Hive 自动解析成 MapReduce 任务由 Hadoop 去具体执行;因此,需要启动 Hadoop,然后再启动 Hive。由于前面已经启动了 Hadoop,所以,这里不需要再次启动 Hadoop。下面在

这个新的终端中执行下面命令进入 Hive:

```
$cd /usr/local/hive
$./bin/hive #启动 Hive
```

启动成功以后,就进入了 hive > 命令提示符状态,可以输入类似 SQL 语句的 Hive QL 语句。

下面需要在 Hive 中创建一个数据库 dblab,命令如下(注意,不是 Shell 命令,而是在 hive>命令提示符状态下的 Hive 命令):

```
hive>create database dblab;
hive>use dblab;
```

#### 4. 创建外部表

关于数据仓库 Hive 的内部表和外部表的区别,可以查看相关网络资料,这里不再赘述。本书采用外部表方式。现在要在数据库 dblab 中创建一个外部表 bigdata\_user,它包含字段(id,uid,item\_id,behavior\_type,item\_category,date,province),在 hive 命令提示符下输入如下命令:

```
hive > CREATE EXTERNAL TABLE dblab.bigdata_user (id INT, uid STRING, item_id STRING, behavior_type INT, item_category STRING, visit_date DATE, province STRING) COMMENT 'Welcome to xmudblab!' ROW FORMAT DELIMITED FIELDS TERMINATED BY '\t' STORED AS TEXTFILE LOCATION '/ bigdatacase/dataset';
```

#### 5. 查询数据

上面已经成功把 HDFS 中的/bigdatacase/dataset 目录下的数据加载到了数据仓库 Hive 中;然后在 hive>命令提示符状态下执行下面命令查看表的信息:

```
hive>use dblab; //使用 dblab 数据库
hive>show tables; //显示数据库中的所有表
hive>show create table bigdata_user; //查看 bigdata_user 表的各种属性
```

上面的 show create table bigdata\_user 语句执行后,会得到如下信息:

```
OK

CREATE EXTERNAL TABLE `bigdata_user`(
   `id` int,
   `uid` string,
   `item_id` string,
```

```
`behavior_type` int,
  `item_category` string,
  `visit_date` date,
  `province` string)
COMMENT 'Welcome to xmu dblab!'
ROW FORMAT SERDE
  'org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe'
WITH SERDEPROPERTIES (
  'field.delim'='\t',
  'serialization.format'='\t')
STORED AS INPUTFORMAT
  'org.apache.hadoop.mapred.TextInputFormat'
OUTPUTFORMAT
  'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
LOCATION
  'hdfs://localhost:9000/bigdatacase/dataset'
TBLPROPERTIES (
  'numFiles'='1',
  'totalSize'='15590786',
  'transient_lastDdlTime'='1480217306')
Time taken: 0.715 seconds, Fetched: 24 row(s)
```

#### 还可以执行下面命令查看表的简单结构:

```
hive>desc bigdata_user;
```

#### 执行结果如下:

```
OK
id
                         int
uid
                         string
item_id
                         string
behavior type
                         int
item category
                         string
visit date
                         date
province
                         string
Time taken: 0.267 seconds, Fetched: 7 row(s)
```

#### 现在可以使用下面命令查询相关数据:

```
hive>select * from bigdata_user limit 10;
hive>select behavior_type from bigdata_user limit 10;
```

# 12.5 Hive 数据分析

本节介绍简单查询分析、查询条数统计分析、关键字条件查询分析、根据用户行为分析和用户实时查询分析。

# 12.5.1 简单查询分析

首先执行一条简单的指令:

hive>select behavior\_type from bigdata\_user limit 10; //查看前 10位用户对商品的行为

#### 执行结果如下:

```
OK

1

1

1

1

1

1

1

1

1

Time taken: 2.561 seconds, Fetched: 10 row(s)
```

如果要查出每位用户购买商品时的多种信息,输出语句格式如下:

select 列 1,列 2,…,列 n from 表名;

例如,查询前20位用户购买商品时的时间和商品的种类,语句如下:

hive>select visit\_date, item\_category from bigdata\_user limit 20;

## 执行结果如下:

```
OK

2014-12-08 4076

2014-12-12 5503

2014-12-12 5503

2014-12-02 9762

2014-12-02 9762

2014-12-02 9762
```

```
2014-12-12 5503
2014-12-12 10894
2014-12-12 10894
2014-12-12 10894
2014-12-12 2825
2014-11-28 2825
2014-12-15 3200
2014-12-03 10576
2014-12-13 10576
2014-12-08 10576
2014-12-08 10576
2014-12-14 7079
2014-12-14 7079
2014-12-02 6669
2014-12-12 5232
Time taken: 0.401 seconds, Fetched: 20 row(s)
```

有时在表中查询可以利用嵌套语句,如果列名太复杂可以设置该列的别名,以简化操作的难度,举例如下:

```
hive>select e.bh, e.it from (select behavior_type as bh, item_category as it from bigdata_user) as e limit 20;
```

上面语句中,"behavior\_type as bh, item\_category as it"是为 behavior\_type 设置别名bh,为 item\_category 设置别名 it,FROM 的括号里的内容,也设置了别名 e,这样调用时就可以使用 e. bh 和 e. it,可以简化代码。

上述代码执行结果如下:

```
OK

1 4076

1 5503

1 5503

1 9762

1 5232

4 9762

1 5503

1 10894

1 6513

1 10894

1 2825

1 3200

1 10576
```

```
1 10576

1 10576

1 10576

1 7079

1 6669

1 5232

Time taken: 0.374 seconds, Fetched: 20 row(s)
```

# 12.5.2 查询条数统计分析

#### 1. 用聚合函数 count()计算出表内有多少行数据

```
hive>select count(*) from bigdata_user;
```

#### 执行结果如下:

```
WARNING: Hive-on-MR is deprecated in Hive 2 and may not be available in the future versions.
Consider using a different execution engine (i.e. spark, tez) or using Hive 1.X releases.
Query ID=hadoop_20161127192506_cb00d4a1-b9e3-426e-a2be-d971a61f686b
Total jobs=1
Launching Job 1 out of 1 \,
Number of reduce tasks determined at compile time: 1
In order to change the average load for a reducer (in bytes):
  set hive.exec.reducers.bytes.per.reducer=<number>
In order to limit the maximum number of reducers:
  set hive.exec.reducers.max=<number>
In order to set a constant number of reducers:
  set mapreduce.job.reduces=<number>
Job running in-process (local Hadoop)
2016-11-27 19:25:10,555 Stage-1 map=0%, reduce=0%
2016-11-27 19:25:12,606 Stage-1 map=100%, reduce=100%
Ended Job=job_local1072810798_0001
MapReduce Jobs Launched:
Stage-Stage-1: HDFS Read: 62395912 HDFS Write: 0 SUCCESS
Total MapReduce CPU Time Spent: 0 msec
OK
300000
Time taken: 6.418 seconds, Fetched: 1 row(s)
```

可以看到,在执行结果的最后面有一个数字是 300000,因为导入到 Hive 中的 small\_user.csv 中包含了 300000 条记录。

# 2. 在函数内部加上 distinct, 查出 uid 不重复的数据有多少条

命令如下:

hive>select count (distinct uid) from bigdata user;

#### 执行结果如下:

OK

270

Time taken: 4.689 seconds, Fetched: 1 row(s)

# 3. 查询不重复的数据有多少条(为了排除客户刷单情况)

命令如下:

hive>select count(\*) from (select uid, item\_id, behavior\_type, item\_category, visit\_date, province from bigdata\_user groupby uid, item\_id, behavior\_type, item\_category, visit\_date, province having count(\*)=1)a;

#### 执行结果如下:

OK

284183

Time taken: 16.05 seconds, Fetched: 1 row(s)

可以看出,排除掉重复信息以后,只有 284183 条记录。需要注意的是,嵌套语句最好取别名,就是上面的 a,否则很容易出现如图 12-3 所示的错误。

FAILED: ParseException line 1:131 cannot recognize input near '<EOF>' '<EOF>' '<

图 12-3 错误信息

# 12.5.3 关键字条件查询分析

#### 1. 以关键字的存在区间为条件的查询

使用 where 关键字可以缩小查询分析的范围和精确度。

(1) 查询 2014 年 12 月 10 日到 2014 年 12 月 13 日有多少人浏览了商品。 命令如下:

hive>select count(\*) from bigdata\_user where behavior\_type='1' and visit\_date<'2014-12-13' and visit\_date>'2014-12-10';

## 执行结果如下:

```
OK
26329
Time taken: 3.058 seconds, Fetched: 1 row(s)
```

(2) 以月的第n 天为统计单位,依次显示第n 天网站卖出去的商品的个数。命令如下:

hive>select count(distinct uid), day(visit\_date) from bigdata\_user where behavior\_type='4
' group by day(visit\_date);

## 执行结果如下:

```
OK
37 1
48 2
42 3
38 4
42 5
33 6
42 7
36 8
34 9
40 10
43 11
98 12
39 13
43 14
42 15
44 16
42 17
66 18
38 19
50 20
33 21
34 22
32 23
47 24
34 25
31 26
30 27
34 28
39 29
38 30
Time taken: 2.378 seconds, Fetched: 30 row(s)
```

#### 2. 关键字赋予定值为条件,对其他数据进行分析

取给定时间和给定地点,求当天发出到该地点的货物的数量。命令如下:

hive>select count(\*) from bigdata\_user where province= '江西' and visit\_date= '2014-12-12' and behavior\_type='4';

#### 执行结果如下:

OK

Time taken: 3.421 seconds, Fetched: 1 row(s)

## 12.5.4 根据用户行为分析

这里只给出查询语句,不再给出执行结果。

1. 查询一件商品在某天的购买比例或浏览比例

hive>select count(\*) from bigdata\_user where visit\_date= '2014-12-11'and behavior\_type= '4'; //查询有多少用户在 2014-12-11 购买了商品

hive>select count(\*) from bigdata\_user where visit\_date= '2014-12-11'; //查询有多少用户在 2014-12-11点击了该店

根据上面语句得到购买数量和点击数量,两个数相除即可得出当天该商品的购买率。

2. 查询某个用户在某一天点击网站占该天所有点击行为的比例(点击行为包括浏览、加入购物车、收藏、购买)

hive>select count(\*) from bigdata\_user where uid=10001082 and visit\_date='2014-12-12'; //查询用户 10001082 在 2014-12-12点击网站的次数

hive>select count(\*) from bigdata\_user where visit\_date='2014-12-12';
//查询所有用户在这一天点击该网站的次数

- 上面两条语句的结果相除,就得到了要求的比例。
- 3. 给定购买商品的数量范围,查询某一天在该网站的购买该数量商品的用户 id

hive>select uid from bigdata\_user where behavior\_type='4' and visit\_date=
'2014-12-12' group by uid having count (behavior\_type='4')>5; //查询某一天在该网站购买商品超过 5次的用户 id

# 12.5.5 用户实时查询分析

查询某个地区的用户当天浏览网站的次数,语句如下:

hive>create table scan(province STRING, scan INT) COMMENT 'This is the search of bigdataday 'ROW FORMAT DELIMITED FIELDS TERMINATED BY '\t' STORED AS TEXTFILE; //创建新的数据表进行存储

hive>insert overwrite table scan select province, count (behavior\_type) from bigdata\_user where behavior\_type='1' group by province; //导入数据

hive>select \* from scan;

//显示结果

#### 执行结果如下:

```
上海市
      8364
云南
       8454
内蒙古
      8172
北京市
      8258
台湾
       8382
吉林
      8272
四川
       8359
天津市
       8478
宁夏
       8205
安徽
       8205
山东
       8236
山西
       8503
广东
       8228
广西
       8358
新疆
       8316
江苏
       8226
江西
       8403
河北
       8363
河南
       8382
浙江
       8310
海南
       8391
湖北
       8183
湖南
       8368
澳门
       8264
甘肃
       8415
福建
       8270
西藏
       8347
贵州
       8505
辽宁
       8292
重庆市
       8506
陕西
       8379
```

青海 8427

香港 8386

黑龙江 8309

Time taken: 0.248 seconds, Fetched: 34 row(s)

# 12.6 Hive、MySQL、HBase 数据互导

本节介绍 Hive 预操作、使用 Sqoop 将数据从 Hive 导入 MySQL、使用 Sqoop 将数据从 MySQL 导入 HBase、使用 HBase Java API 把数据从本地导入到 HBase 中。

## 12.6.1 Hive 预操作

1. 创建临时表 user\_action

命令如下:

hive>create table dblab.user\_action(id STRING, uid STRING, item\_id STRING, behavior\_type STRING, item\_category STRING, visit\_date DATE, province STRING) COMMENT 'Welcome to XMU dblab! 'ROW FORMAT DELIMITED FIELDS TERMINATED BY '\t' STORED AS TEXTFILE;

这个命令执行完以后, Hive 会自动在 HDFS 文件系统中创建对应的数据文件/user/hive/warehouse/dblab. db/user\_action。

现在可以新建一个终端,执行命令查看一下,确认这个数据文件在 HDFS 中确实已经被创建,在新建的终端中执行下面命令:

\$cd /usr/local/hadoop

\$./bin/hdfs dfs-ls /user/hive/warehouse/dblab.db/user\_action

这条命令执行以后,可以看到如下结果:

-rwxr-xr-x1 hadoop supergroup 15590786 2016-11-27 21:57 /user/hive/warehouse/dblab.db/user action/000000 0

上述结果可以说明,这个数据文件在 HDFS 中确实已经被创建。注意,这个 HDFS 中的数据文件,在后面的"使用 HBase Java API 把数据从本地导入到 HBase 中"部分会使用到。

# 2. 将 bigdata\_user 表中的数据插入到 user\_action

在"Hive 数据分析"中,已经在 Hive 中的 dblab 数据库中创建了一个外部表 bigdata\_user。下面把 dblab. bigdata\_user 数据插入到 dblab. user\_action 表中,命令如下:

hive>INSERT OVERWRITE TABLE dblab.user\_action select \* from dblab.bigdata\_user;

然后执行下面命令查询上面的插入命令是否成功执行:

```
hive>select * from user_action limit 10;
```

执行结果如图 12-4 所示。

```
hive> use dblab;
Time taken: 0.353 seconds
hive> select * from user_action limit 10;
                                                                           香港
        10001082
                         285259775
                                                  4076
                         4368907 1
                                          5503
                                                  2014-12-12
        10001082
                         4368907 1
                                          5503
                                                  2014-12-12
        10001082
        10001082
                                                  9762
                         53616768
                                                          2014-12-02
                                                  5232
                                                          2014-12-12
                         151466952
        10001082
        10001082
                         53616768
                                                  9762
                                                          2014-12-02
                         290088061
                                                  5503
                                                          2014-12-12
         10001082
         10001082
                         298397524
                                          1
                                                  10894
                                                          2014-12-12
                                                           2014-12-12
        10001082
                         32104252
                                                  6513
        10001082
                         323339743
                                                  10894
                                                          2014-12-12
Time taken: 0.652 seconds, Fetched: 10 row(s)
```

图 12-4 select 语句执行结果

# 12.6.2 使用 Sqoop 将数据从 Hive 导入 MySQL

- 1. 将前面生成的临时表数据从 Hive 导入到 MySQL 中
- 1) 登录 MySQL

在 Linux 系统中新建一个终端,执行下面命令:

```
$mysql -u root -p
```

为了简化操作,本书直接使用 root 用户登录 MySQL 数据库,但是,在实际应用中,建议在 MySQL 中再另外创建一个用户。

执行上面命令以后,就进入 mysql>命令提示符状态。

2) 创建数据库

```
mysql>show databases; #显示所有数据库
mysql>create database dblab; #创建 dblab 数据库
mysql>use dblab; #使用数据库
```

注意: 使用下面命令查看数据库的编码:

```
mysql>show variables like "char%";
```

会显示类似图 12-5 所示的结果。

请确认当前编码格式为 utf8,否则无法导入中文。上面的查询结果中,character\_set\_

+	·+	
Variable_name	Value	
+	· +	
character_set_client	utf8	
character_set_connection	utf8	
character_set_database	latin1	
character_set_filesystem	binary	
character_set_results	utf8	
character_set_server	latin1	
character_set_system	utf8	
character_sets_dir	/usr/share/mysql/charsets/	
+		
8 rows in set (0.00 sec)		

图 12-5 初始的数据库字符集编码格式

database 的编码格式是 latin1,不是 utf8,需要修改。如果当前编码不是 utf8,请参考本书附录 B,把编码格式修改为 utf8。修改了编码格式后,再次执行 show variables like "char%" 命令会得到如图 12-6 所示的结果。

+	++
Variable_name	Value
character_set_client   character_set_connection   character_set_database   character_set_filesystem   character_set_results   character_set_server   character_set_system   character_sets_dir	utf8
8 rows in set (0.00 sec)	++

图 12-6 修改后的数据库字符集编码格式

从上面修改后的结果可以看出,此时的 character\_set\_database 的编码格式是 utf8。

#### 3) 创建表

下面在 MySQL 的数据库 dblab 中创建一个新表 user\_action,并设置其编码为 utf8:

mysql>CREATE TABLE `dblab`.`user\_action` (`id` varchar(50), `uid` varchar(50), `item\_id`
varchar(50), `behavior\_type` varchar(10), `item\_category` varchar(50), `visit\_date` DATE,`
province` varchar(20)) ENGINE=InnoDB DEFAULT CHARSET=utf8;

提示:语句中的引号是反引号(在键盘左上角 Esc 键下方),不是单引号,。创建成功后,输入下面命令退出 MySQL:

mysql>exit

#### 4) 导入数据

注意: 刚才已经退出 MySQL,回到了 shell 命令提示符状态。下面可以执行数据导入

#### 操作:

```
$cd /usr/local/sqoop
$./bin/sqoop export --connect jdbc:mysql://localhost:3306/dblab --username
root --password hadoop --table user_action --export -dir '/user/hive/
warehouse/dblab.db/user_action' --fields-terminated-by '\t'; #导入命令
```

#### 上面命令的具体含义如表 12-5 所示。

表 12-5 sqoop export 命令的含义

命 令	含 义
./bin/sqoop export	数据从 Hive 复制到 MySQL 中
connect jdbc:mysql://localhost:3306/dblab	数据库的连接地址
username root	MySQL 数据库的登录用户名
password hadoop	MySQL 数据库的登录密码
table user_action	MySQL 中的表,即将被导入的表名称
export-dir '/user/hive/warehouse/dblab. db/user_action '	Hive 中被导出的文件
fields-terminated-by '\t'	Hive 中被导出的文件字段的分隔符

#### 上面命令执行以后,如果输出以下信息,则表示导入成功:

```
16/11/28 09:18:12 INFO mapreduce.Job: Job job_local1006738657_0001 completed successfully
16/11/28 09:18:12 INFO mapreduce.Job: Counters: 20
    File System Counters
        FILE: Number of bytes read=72216458
        FILE: Number of bytes written=73973600
        FILE: Number of read operations=0
        FILE: Number of large read operations=0
        FILE: Number of write operations=0
        HDFS: Number of bytes read=38989562
        HDFS: Number of bytes written=0
        HDFS: Number of read operations=78
        HDFS: Number of large read operations=0
        HDFS: Number of write operations=0
    Map-Reduce Framework
        Mapinput records=300000
        Map output records=300000
        Input split bytes=696
```

```
Spilled Records=0
Failed Shuffles=0
Merged Map outputs=0
GC time elapsed (ms)=145
Total committed heap usage (bytes)=511180800
File Input Format Counters
Bytes Read=0
File Output Format Counters
Bytes Written=0
16/11/28 09:18:12 INFO mapreduce.ExportJobBase: Transferred 37.1833 MB in 29.2772 seconds (1.27 MB/sec)
16/11/28 09:18:12 INFO mapreduce.ExportJobBase: Exported 300000 records.
```

# 2. 查看 MySQL 中 user\_action 表数据

下面需要再次启动 MySQL,进入 mysql>命令提示符状态:

```
$mysql-u root-p
```

系统会提示输入 MySQL 的 root 用户的密码,本书中安装的 MySQL 数据库的 root 用户的密码是 hadoop。

然后执行下面命令查询 user\_action 表中的数据:

```
mysql>use dblab;
mysql>select * from user_action limit 10;
```

会得到类似下面的查询结果:

```
+----+
| id | uid | item id | behavior type | item category | visit date | province |
+----+
                                       | 2014-12-08 |香港
| 225653 | 102865660 | 164310319 | 1
                          | 5027
                                      | 2014-12-13 |天津市
| 225654 | 102865660 | 72511722 | 1
                             | 1121
                                    | 2014-11-30 | 江苏
                            | 5027
| 225655 | 102865660 | 334372932 | 1
                                    | 2014-12-02 |广东
| 225656 | 102865660 | 323237439 | 1
                           | 5027
| 225657 | 102865660 | 323237439 | 1
                                    | 2014-12-07 |山西
                          | 5027
                                    | 2014-12-13 | 内蒙古 |
| 225658 | 102865660 | 34102362 | 1
                          | 1863
                                    | 2014-11-26 |湖北
| 225659 | 102865660 | 373499226 | 1
                          | 12388
| 225660 | 102865660 | 271583890 | 1
                             | 5027
                                    | 2014-12-06 | 山西
                            | 5399
                                      | 2014-11-26 | 澳门
| 225661 | 102865660 | 384764083 | 1
                           | 5027
                                     | 2014-12-03 |广东
| 225662 | 102865660 | 139671483 | 1
+----+
10 \text{rows in set } (0.00 \text{ sec})
```

至此,从 Hive 导入数据到 MySQL 中的操作,顺利完成。

# 12.6.3 使用 Sqoop 将数据从 MySQL 导入 HBase

1. 启动 Hadoop 集群、MySQL 服务、HBase 服务

之前已经启动了 Hadoop 集群和 MySQL 服务,这里请确认已经按照前面操作启动成功。现在需要再启动 HBase 服务。本书中,HBase 的安装目录是/usr/local/hbase,而且本书中,HBase 被配置为使用 HDFS 来存储数据。

在 Linux 系统中新建一个终端,执行下面命令:

\$cd /usr/local/hbase
\$./bin/start-hbase.sh

#### 2. 启动 HBase Shell

执行如下命令启动 hBase shell:

\$cd /usr/local/hbase
\$./bin/hbase shell

启动成功后,就进入了 hbase>命令提示符状态。

3. 创建表 user\_action

命令如下:

hbase>create 'user\_action', { NAME=>'f1', VERSIONS=>5}

上面命令执行后,会在 HBase 中创建一个 user\_action 表,这个表中有一个列族 f1(把列族名称取为其他名称也可以,例如列族名称为 userinfo),历史版本保留数量为 5。

## 4. 导入数据

下面新建一个终端,执行下面命令导入数据:

\$cd /usr/local/sqoop
\$./bin/sqoop import -- connect jdbc:mysql://localhost:3306/dblab -- username
root -- password hadoop -- table user\_action -- hbase- table user\_action -- column
- family f1 -- hbase- row- key id -- hbase- create- table- m 1

注意: IP 部分改为本机 IP 地址或 localhost。同时, HBase 只支持十六进制存储中文。上面这条命令的具体含义如表 12-6 所示。

表 12-6 sqoop import 命令的具体含义

命 令	含 义
./bin/sqoop import	执行导入操作
connect jdbc:mysql://localhost:3306/dblab	数据库连接地址
username root	登录数据库的用户名
password hadoop	登录数据库的密码
table user_action	所要访问的数据库表
hbase-table user_action	HBase 中表的名称
column-family f1	列族名称
hbase-row-key id	HBase 行键
hbase-create-table	是否在不存在情况下创建表
-m 1	启动 Map 的数量

执行上面的 sqoop import 命令后,会得到类似下面的结果(省略了很多非重要的屏幕信息):

```
16/11/28 10:03:40 INFO mapreduce.Job: Counters: 20
    File System Counters
        FILE: Number of bytes read=39428226
        FILE: Number of bytes written= 40095167
        FILE: Number of read operations=0
        FILE: Number of large read operations=0
        FILE: Number of write operations=0
        HDFS: Number of bytes read=0
        HDFS: Number of bytes written=0
        HDFS: Number of read operations=0
        HDFS: Number of large read operations=0
        HDFS: Number of write operations=0
    Map-Reduce Framework
        Map input records=300000
        Map output records=300000
        Input split bytes=87
        Spilled Records=0
        Failed Shuffles=0
        Merged Map outputs=0
        GC time elapsed (ms)=1018
        Total committed heap usage (bytes) = 127795200
    File Input Format Counters
        Bytes Read=0
    File Output Format Counters
```

```
Bytes Written=0
```

16/11/28 10:03:40 INFO mapreduce.ImportJobBase: Transferred 0 bytes in 69.7527 seconds (0 bytes/sec)

16/11/28 10:03:40 INFO mapreduce.ImportJobBase: Retrieved 300000 records.

#### 5. 查看 HBase 中 user\_action 表数据

现在再次切换到 HBase Shell 运行的那个终端窗口,在 hbase>命令提示符下,执行下面命令查询刚才导入的数据:

```
hbase>scan 'user_action', {LIMIT=>10} #只查询前面 10 行
```

#### 因为有 30 万条记录,所以,用 LIMIT 只查询前 10 行的记录,会得到类似下面的结果:

```
1
         column=f1:behavior_type, timestamp=1480298573684, value=1
1
         column=f1:item category, timestamp=1480298573684, value=4076
         column=f1:item id, timestamp=1480298573684, value=285259775
1
         column=f1:province, timestamp=1480298573684, value=\xE5\xB9\xBF\xE4\xB8\x9C
1
         column=f1:uid, timestamp=1480298573684, value=10001082
1
         column=f1:visit date, timestamp=1480298573684, value=2014-12-08
10
         column=f1:behavior type, timestamp=1480298573684, value=1
         column=f1:item_category, timestamp=1480298573684, value=10894
10
10
         column=f1:item id, timestamp=1480298573684, value=323339743
         column=f1:province, timestamp=1480298573684, value=\xE5\xB1\xB1\xE4\xB8\x9C
10
10
         column=f1:uid, timestamp=1480298573684, value=10001082
10
         column=f1:visit date, timestamp=1480298573684, value=2014-12-12
         column=f1:behavior type, timestamp=1480298573684, value=1
100
         column=f1:item_category, timestamp=1480298573684, value=10576
100
100
         column=f1:item id, timestamp=1480298573684, value=275221686
100
         column=f1:province, timestamp=1480298573684, value=\xE6\xB9\x96\xE5\x8C\x97
100
         column=f1:uid, timestamp=1480298573684, value=10001082
         column=f1:visit date, timestamp=1480298573684, value=2014-12-02
100
1000
         column=f1:behavior type, timestamp=1480298573684, value=1
1000
         column=f1:item category, timestamp=1480298573684, value=3381
1000
         column=f1:item id, timestamp=1480298573684, value=168463559
1000
         column=f1:province, timestamp=1480298573684, value=\xE5\xB1\xB1\xE8\xA5\xBF
1000
         column=f1:uid, timestamp=1480298573684, value=100068031
1000
         column=f1:visit date, timestamp=1480298573684, value=2014-12-02
10000
         column=f1:behavior type, timestamp=1480298575888, value=1
```

```
10000
          column=f1:item category, timestamp=1480298575888, value=12488
10000
          column=f1:item id, timestamp=1480298575888, value=45571867
10000
          column=f1:province, timestamp=1480298575888, value=\xE6\xB9\x96\xE5\x8C\x97
10000
          column=f1:uid, timestamp=1480298575888, value=100198255
10000
           column=f1:visit date, timestamp=1480298575888, value=2014-12-05
100000
          column=f1:behavior type, timestamp=1480298594850, value=1
100000
          column=f1:item category, timestamp=1480298594850, value=6580
100000
          column=f1:item id, timestamp=1480298594850, value=78973192
          column=f1:province, timestamp=1480298594850, value=\xE5\xB1\xB1\xE4\xB8\x9C
100000
100000
          column=f1:uid, timestamp=1480298594850, value=101480065
100000
          column=f1:visit date, timestamp=1480298594850, value=2014-11-29
100001
          column=f1:behavior type, timestamp=1480298594850, value=1
100001
          column=f1:item category, timestamp=1480298594850, value=3472
100001
          column=f1:item id, timestamp=1480298594850, value=34929314
          column=f1:province, timestamp=1480298594850, value=\xE5\x8C\x97\xE4\xBA\xAC\
100001
          xE5\xB8\x82
100001
          column=f1:uid, timestamp=1480298594850, value=101480065
100001
          column=f1:visit date, timestamp=1480298594850, value=2014-12-15
100002
          column=f1:behavior type, timestamp=1480298594850, value=1
100002
          column=f1:item category, timestamp=1480298594850, value=10392
100002
          column=f1:item id, timestamp=1480298594850, value=401104894
100002
          column=f1:province, timestamp=1480298594850, value=\xE6\xB1\x9F\xE8\xA5\xBF
100002
          column=f1:uid, timestamp=1480298594850, value=101480065
100002
          column=f1:visit date, timestamp=1480298594850, value=2014-11-29
100003
          column=f1:behavior type, timestamp=1480298594850, value=1
100003
          column=f1:item category, timestamp=1480298594850, value=5894
100003
          column=f1:item id, timestamp=1480298594850, value=217913901
100003
          column=f1:province, timestamp=1480298594850, value=xE9xBBx91xE9xBEx99
          xE6\xB1\x9F
100003
          column=f1:uid, timestamp=1480298594850, value=101480065
100003
          column=f1:visit date, timestamp=1480298594850, value=2014-12-04
100004
          column=f1:behavior type, timestamp=1480298594850, value=1
          column=f1:item_category, timestamp=1480298594850, value=12189
100004
100004
            column=f1:item id, timestamp=1480298594850, value=295053167
          100004
100004
          column=f1:uid, timestamp=1480298594850, value=101480065
          column=f1:visit date, timestamp=1480298594850, value=2014-11-26
100004
10 row(s) in 2.1550 seconds
```

注意: 用 limit10 是返回 HBase 表中的前面 10 行数据,但是,上面的结果,从"行数"来看,似乎不是 10 行,而是远远多于 10 行。这是因为,HBase 在显示数据的时候,和关系型数据库 MySQL 是不同的,每行显示的不是一行记录,而是一个"单元格"。

# 12.6.4 使用 HBase Java API 把数据从本地导入到 HBase 中

## 1. 启动 Hadoop 集群、HBase 服务

首先确保启动了 Hadoop 集群和 HBase 服务。如果还没有启动,在 Linux 系统中打开一个终端。首先,按照下面命令启动 Hadoop:

\$cd /usr/local/hadoop
\$./sbin/start-all.sh

然后按照下面命令启动 HBase:

\$cd /usr/local/hbase
\$./bin/start-hbase.sh

# 2.数据准备

实际上,也可以编写 Java 程序,直接从 HDFS 中读取数据加载到 HBase。但是,这里展示的是如何用 Java 程序把本地数据导入到 HBase 中。只要对程序做简单修改,就可以实现从 HDFS 中读取数据加载到 HBase。

首先将之前的 user\_action 数据从 HDFS 复制到 Linux 系统的本地文件系统中,命令如下:

\$cd /usr/local/bigdatacase/dataset

\$/usr/local/hadoop/bin/hdfs dfs -get /user/hive/warehouse/dblab.db/user\_

action . #将 HDFS上的 user\_action数据复制到本地当前目录,"."表示当前目录

\$cat ./user action/\* | head - 10 #查看前 10 行数据

\$cat ./user\_action/00000 \* > user\_action.output

#将 00000 \* 文件复制一份重命名为 user\_action.output, \* 表示通配符

\$head user\_action.output #查看 user\_action.output前 10 行

#### 3. 编写数据导入程序

这里采用 Eclipse 编写 Java 程序实现 HBase 数据导入功能,具体代码如下:

import java.io.BufferedReader;

import java.io.FileInputStream;

import java.io.IOException;

import java.io.InputStreamReader;

import java.util.List;

```
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.hbase.HBaseConfiguration;
import org.apache.hadoop.hbase.KeyValue;
import org.apache.hadoop.hbase.client.Get;
import org.apache.hadoop.hbase.client.HBaseAdmin;
import org.apache.hadoop.hbase.client.HTable;
import org.apache.hadoop.hbase.client.Put;
import org.apache.hadoop.hbase.client.Result;
import org.apache.hadoop.hbase.client.ResultScanner;
import org.apache.hadoop.hbase.client.Scan;
import org.apache.hadoop.hbase.util.Bytes;
public class HBaseImportTest extends Thread {
    public Configuration config;
    public HTable table;
    public HBaseAdmin admin;
    public HBaseImportTest() {
        config=HBaseConfiguration.create();
        config.set("hbase.master", "master:60000");
//
        config.set("hbase.zookeeper.quorum", "master");
//
        try {
            table=new HTable(config, Bytes.toBytes("user_action"));
            admin=new HBaseAdmin(config);
        } catch (IOException e) {
            e.printStackTrace();
    public static void main(String[] args) throws Exception {
        if (args.length==0) {
                        //第一个参数是该 jar 所使用的类,第二个参数是数据集所存放的路径
            throw new Exception ("You must set input path!");
        String fileName=args[args.length-1]; //输入的文件路径是最后一个参数
        HBaseImportTest test=new HBaseImportTest();
        test.importLocalFileToHBase(fileName);
    public void importLocalFileToHBase (String fileName) {
        long st=System.currentTimeMillis();
        BufferedReader br=null;
        try {
            br=new BufferedReader (new InputStreamReader (new FileInputStream (
                    fileName)));
            String line=null;
            int count=0;
            while ((line=br.readLine()) !=null) {
                count++;
                put(line);
```

```
if (count % 10000==0)
                 System.out.println(count);
         }
    } catch (IOException e) {
        e.printStackTrace();
    } finally {
        if (br !=null) {
             try {
                 br.close();
             } catch (IOException e) {
                 e.printStackTrace();
         }
        try {
             table.flushCommits();
             table.close(); //must close the client
        } catch (IOException e) {
             e.printStackTrace();
         }
    long en2=System.currentTimeMillis();
    System.out.println("Total Time: "+ (en2-st)+" ms");
@ SuppressWarnings("deprecation")
public void put (String line) throws IOException {
    String[] arr=line.split("\t", -1);
    String[] column= {"id", "uid", "item_id", "behavior_type", "item_
    category", "date", "province");
    if (arr.length==7) {
        Put put=new Put(Bytes.toBytes(arr[0]));//rowkey
         for(int i=1;i<arr.length;i++){</pre>
             put.add(Bytes.toBytes("f1"), Bytes.toBytes(column[i]),Bytes.
             toBytes(arr[i]));
        table.put(put); //put to server
public void get (String rowkey, String column Family, String column,
        int versions) throws IOException {
    long st=System.currentTimeMillis();
    Get get=new Get (Bytes.toBytes (rowkey));
    get.addColumn(Bytes.toBytes(columnFamily), Bytes.toBytes(column));
    Scan scanner=new Scan (get);
    scanner.setMaxVersions(versions);
    ResultScanner rsScanner=table.getScanner(scanner);
```

上述代码也可以直接到本书官网"下载专区"下载,位于"代码"目录的"第 12 章"子目录下,文件名是 ImportHBase. java。

参照第5章的内容,在 Eclipse 中编写上述代码,并打包成可执行 jar 包,命名为 ImportHBase. jar;然后在/usr/local/bigdatacase/目录下面新建一个 hbase 子目录,用来存放 ImportHBase. jar。

#### 4. 数据导入

现在开始执行数据导入操作。使用上面编写的 Java 程序 Import HBase. jar,将数据从本地导入 HBase 中。

**注意**: 在导入之前,先清空 user\_action 表。在之前已经打开的 HBase Shell 窗口中(也就是在 hbase>命令提示符下)执行下面操作:

```
hbase>truncate 'user_action'
```

下面就可以运行 hadoop jar 命令,来运行刚才的 Java 程序:

```
$/usr/local/hadoop/bin/hadoop jar /usr/local/bigdatacase/hbase/ImportHBase. jar HBaseImportTest /usr/local/bigdatacase/dataset/user_action.output
```

上面这条命令的含义如表 12-7 所示。

表 12-7 hadoop jar 命令的含义

命令	含 义
/usr/local/hadoop/bin/hadoop jar	hadoop jar 包执行方式
/usr/local/bigdatacase/hbase/ImportHBase.jar	jar 包的路径
HBaseImportTest	主函数入口
/usr/local/bigdatacase/dataset/user_action.output	main 方法接收的参数 args,用来指定输入文件的 路径

这个命令大概会执行 3min 左右,执行过程中,屏幕上会打印出执行进度,每执行 1 万条,对打印出一行信息,所以,整个执行过程屏幕上显示如下信息:

```
10000
20000
30000
40000
50000
60000
70000
80000
90000
100000
110000
120000
130000
140000
150000
160000
170000
180000
190000
200000
210000
220000
230000
240000
250000
260000
270000
280000
290000
300000
Total Time: 259001 ms
```

# 5. 查看 HBase 中 user\_action 表数据

下面再次切换到 HBase Shell 窗口,执行下面命令查询数据:

```
habse>scan 'user_action',{LIMIT=>10} #只查询前面 10 行
```

可以得到类似下面的查询结果:

```
1
          column=f1:behavior type, timestamp=1480298573684, value=1
1
          column=f1:item category, timestamp=1480298573684, value=4076
1
          column=f1:item id, timestamp=1480298573684, value=285259775
1
          column=f1:province, timestamp=1480298573684, value=\xE5\xB9\xBF\xE4\xB8\x9C
1
          column=f1:uid, timestamp=1480298573684, value=10001082
1
          column=f1:visit date, timestamp=1480298573684, value=2014-12-08
10
          column=f1:behavior type, timestamp=1480298573684, value=1
10
          column=f1:item category, timestamp=1480298573684, value=10894
10
          column=f1:item id, timestamp=1480298573684, value=323339743
          column=f1:province, timestamp=1480298573684, value=\xE5\xB1\xB1\xE4\xB8\x9C
10
10
          column=f1:uid, timestamp=1480298573684, value=10001082
10
          column=f1:visit date, timestamp=1480298573684, value=2014-12-12
100
          column=f1:behavior type, timestamp=1480298573684, value=1
100
          column=f1:item_category, timestamp=1480298573684, value=10576
100
          column=f1:item id, timestamp=1480298573684, value=275221686
100
          column=f1:province, timestamp=1480298573684, value=xE6xB9x96xE5x8Cx97
100
          column=f1:uid, timestamp=1480298573684, value=10001082
100
          column=f1:visit date, timestamp=1480298573684, value=2014-12-02
1000
          column=f1:behavior type, timestamp=1480298573684, value=1
1000
          column=f1:item category, timestamp=1480298573684, value=3381
1000
          column=f1:item id, timestamp=1480298573684, value=168463559
1000
          column=f1:province, timestamp=1480298573684, value=\xE5\xB1\xB1\xE8\xA5\xBF
1000
          column=f1:uid, timestamp=1480298573684, value=100068031
1000
          column=f1:visit date, timestamp=1480298573684, value=2014-12-02
10000
          column=f1:behavior type, timestamp=1480298575888, value=1
10000
          column=f1:item_category, timestamp=1480298575888, value=12488
          column=f1:item id, timestamp=1480298575888, value=45571867
10000
10000
          column=f1:province, timestamp=1480298575888, value=\xE6\xB9\x96\xE5\x8C\x97
10000
          column=f1:uid, timestamp=1480298575888, value=100198255
10000
          column=f1:visit date, timestamp=1480298575888, value=2014-12-05
100000
          column=f1:behavior type, timestamp=1480298594850, value=1
100000
          column=f1:item category, timestamp=1480298594850, value=6580
100000
          column=f1:item id, timestamp=1480298594850, value=78973192
100000
          column=f1:province, timestamp=1480298594850, value=\xE5\xB1\xB1\xE4\xB8\x9C
100000
          column=f1:uid, timestamp=1480298594850, value=101480065
100000
          column=f1:visit date, timestamp=1480298594850, value=2014-11-29
          column=f1:behavior type, timestamp=1480298594850, value=1
100001
100001
          column=f1:item category, timestamp=1480298594850, value=3472
```

100001	column=f1:item_id, timestamp=1480298594850, value=34929314
100001	$column=f1:province,\ timestamp=1480298594850,\ value=\xE5\x8C\x97\xE4\xBA\xAC\xAC\xBA\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xBA\xAC\xAC\xAC\xAC\xAC\xAC\xAC\xAC\xAC\xA$
	xE5\xB8\x82
100001	column=f1:uid, timestamp=1480298594850, value=101480065
100001	column=f1:visit_date, timestamp=1480298594850, value=2014-12-15
100002	column=f1:behavior_type, timestamp=1480298594850, value=1
100002	column=f1:item_category, timestamp=1480298594850, value=10392
100002	column=f1:item_id, timestamp=1480298594850, value=401104894
100002	$column = f1: province, timestamp = 1480298594850, value = \xE6\xB1\x9F\xE8\xA5\xBF$
100002	column=f1:uid, timestamp=1480298594850, value=101480065
100002	column=f1:visit_date, timestamp=1480298594850, value=2014-11-29
100003	column=f1:behavior_type, timestamp=1480298594850, value=1
100003	column=f1:item_category, timestamp=1480298594850, value=5894
100003	column=f1:item_id, timestamp=1480298594850, value=217913901
100003	column=f1:province, timestamp=1480298594850, value=\xE9\xBB\x91\xE9\xBE\x99\
	xE6\xB1\x9F
100003	column=f1:uid, timestamp=1480298594850, value=101480065
100003	column=f1:visit_date, timestamp=1480298594850, value=2014-12-04
100004	column=f1:behavior_type, timestamp=1480298594850, value=1
100004	column=f1:item_category, timestamp=1480298594850, value=12189
100004	column=f1:item_id, timestamp=1480298594850, value=295053167
100004	$column = f1: province, timestamp = 1480298594850, value = \xE6\xB5\xB7\xE5\xBD\x97$
100004	column=f1:uid, timestamp=1480298594850, value=101480065
100004	column=f1:visit_date, timestamp=1480298594850, value=2014-11-26
10 row(s	) in 0.6380 seconds

至此,步骤(3)的实验内容顺利结束。

# 12.7 利用 R 进行数据可视化分析

本节介绍安装 R、安装依赖库和可视化分析等。

## 12.7.1 安装 R

Ubuntu 自带的 APT 包管理器中的 R 安装包总是落后于标准版,因此,需要添加新的 镜像源,把 APT 包管理中的 R 安装包更新到最新版。

登录 Linux 系统,打开一个终端,并注意保持网络连通,可以访问互联网,因为安装过程要下载各种安装文件。

首先利用 vim 编辑器打开/etc/apt/sources. list 文件,命令如下:

\$sudo vim /etc/apt/sources.list

在文件的最后一行添加厦门大学的镜像源:

deb http://mirrors.xmu.edu.cn/CRAN/bin/linux/ubuntu/trusty/

保存文件退出 vim 编辑器,然后,执行如下命令更新软件源列表:

\$sudo apt-get update

如果更新软件源出现"由于没有公钥无法验证签名"的错误,请执行如下命令:

\$sudo apt-key adv -- keyserver keyserver.ubuntu.com -- recv- keys 51716619E084DAB9

接下来执行如下命令安装 R 语言:

\$sudo apt-get install r-base

系统会提示"您希望继续执行吗? [y/n]",可以直接从键盘输入 y,按 Enter 键就可以 顺利安装结束。安装结束后,可以执行下面命令启动 R:

\$R

启动后会显示如下信息,并进入>命令提示符状态:

R version 3.3.2 (2016-10-31)-- "Sincere Pumpkin Patch"
Copyright (C) 2016 The R Foundation for Statistical Computing
Platform: x86\_64-pc-linux-gnu (64-bit)

R是自由软件,不带任何担保。

在某些条件下你可以将其自由散布。

用'license()'或'licence()'来看散布的详细条件。

R是个合作成果,有许多人为之做出了贡献。

用'contributors()'来看合作者的详细情况。

用'citation()'会告诉你如何在出版物中正确地引用 R或 R程序包。

用'demo()'来看一些示范程序,用'help()'来阅读在线帮助文件,或

用 'help.start()'通过 HTML浏览器来看帮助文件。

用'q()'退出 R。

>

其中,>是 R 的命令提示符,可以在后面输入 R 语言命令。 最后可以执行下面命令退出 R:

## 12.7.2 安装依赖库

为了完成可视化分析功能,需要为 R 安装一些依赖库,包括 RMySQL、ggplot2、devtools 和 recharts。其中,RMySQL是一个提供了访问 MySQL 数据库的 R 语言接口程序的 R 语言依赖库,ggplot2 和 recharts 则是 R 语言中提供绘图可视化功能的依赖库。

启动 R 进入 R 命令提示符状态,执行如下命令安装 RMySQL:

> install.packages('RMySQL')

上面命令执行后,屏幕会提示"Would you like to user a personal library instead?(y/n)"等问题,只要遇到提问,都在键盘输入 y 后按 Enter 键即可。然后,屏幕会显示"一在此连线阶段时请选用 CRAN 的镜子—",并弹出一个白色背景的竖条形窗口,窗口标题是HTTPS CRAN mirros,标题下面列出了很多国家的镜像列表,可以选择位于 China 的镜像,例如,选择 China(Beijing)[https],然后单击 OK 按钮,就可以开始安装。安装过程需要几分钟时间,当然,安装过程所需时间,也和当前网络速度有关系。

由于不同用户的 Ubuntu 开发环境不一样,安装过程有很大可能会因为缺少组件而导致失败,例如,可能会出现如下错误信息:

Configuration failed because libmysqlclient was not found. Try installing:

- \* deb: libmariadb-client-lgpl-dev (Debian, Ubuntu 16.04) libmariadbclient-dev (Ubuntu 14.04)
- \* rpm: mariadb-devel | mysql-devel (Fedora, CentOS, RHEL)
- \* csw: mysql56 dev (Solaris)
- \* brew: mariadb-connector-c (OSX)

......

ERROR: configuration failed for package 'RMySQL'

\* removing '/home/hadoop/R/x86 64-pc-linux-gnu-library/3.3/RMySQL'

#### 下载的程序包在

'/tmp/RtmpvEArxz/downloaded\_packages'里

Warning message:

In install.packages("RMySQL"):安装程序包'RMySQL'时退出状态的值不是 0

如果安装过程出现上述错误信息,那么,就需要输入 q(),退出 R 命令提示符状态,回到 Shell 状态;然后根据错误信息进行相关操作。例如,如果采用 Ubuntu16.04 系统,那么,根据上面的英文错误信息,就需要在 Shell 命令提示符状态下执行下面命令安装 libmariadb-client-lgpl-dev:

\$sudo apt-get install libmariadb-client-lgpl-dev

再次输入下面命令进入 R 命令提示符状态:

启动后进入>命令提示符状态;然后执行如下命令安装绘图包 ggplot2:

```
> install.packages('ggplot2')
```

屏幕会显示"一在此连线阶段时请选用 CRAN 的镜子—",并会弹出一个白色背景的竖条形窗口,窗口标题是 HTTPS CRAN mirros,标题下面列出了很多国家的镜像列表,可以选择位于 China 的镜像,例如,选择 China(Beijing)[https],然后单击 OK 按钮,就开始安装了。如果还出现缺少组件的错误信息,按照上面的处理办法就可以顺利解决。这个命令运行后,大概需要安装 10min,当然,安装过程所需时间,也和当前网络速度有关系。

接下来继续运行下面命令安装 devtools:

```
> install.packages('devtools')
```

如果在上面安装 devtools 的过程中,又出现了错误信息,处理方法很简单,还是按照上面介绍的方法,根据屏幕上给出的英文错误信息,缺少什么软件,就用 sudo apt-get install命令安装该软件即可。例如,在 Ubuntu16.04 上执行 devtools 安装时,可能会出现 3 次错误,根据每次错误的英文提示信息,就需要 3 个软件: libssl-dev、libssh2-1-dev、libcurl4-openssl-dev。安装命令如下:

```
$sudo apt-get install libssl-dev
$sudo apt-get install libssh2-1-dev
$sudo apt-get install libcurl4-openssl-dev
```

最后在 R 命令提示符下,再执行如下命令安装 taiyun/recharts:

```
>devtools::install github('taiyun/recharts')
```

## 12.7.3 可视化分析

以下在分析过程中所使用的函数方法,都可以在 R 命令提示符下使用"?"命令查询函数的相关文档,例如,查询 sort()函数如何使用,可以使用如下命令:

```
>?sort
```

这时就会进入冒号":"提示符状态(即帮助文档状态),在冒号后面输入 q,即可退出帮助文档状态,返回到 R 提示符状态。

#### 1. 连接 MySQL,并获取数据

在 Linux 系统中新建另外一个终端,然后执行下面命令启动 MySQL 数据库:

\$service mysql start

屏幕上会弹出窗口提示你输入密码,本书的 MySQL 数据库的用户名是 root,密码是 hadoop,所以,直接输入密码 hadoop,就可以成功启动 MySQL 数据库。

下面需要查看一下 MySQL 数据库中的数据,首先执行如下命令进入 MySQL 命令提示符状态:

```
$mysql-u root-p
```

系统会提示输入密码,可以输入密码 hadoop,这样就可以进入 mysql>提示符状态。接下来可以输入一些 SQL 语句查询数据:

```
mysql>use dblab;
mysql>select * from user_action limit 10;
```

上面语句执行后,可以查看到数据库 dblab 中的 user\_action 表的前 10 行记录,查询结果如下:

```
+----+
|id | uid | item_id | behavior_type | item_category | visit_date | province
| 2014-12-08 | 香港
                               | 5027
| 225653 | 102865660 | 164310319 | 1
                                         | 2014-12-13 |天津市
                               | 1121
| 225654 | 102865660 | 72511722 | 1
                                         | 2014-11-30 |江苏
| 225655 | 102865660 | 334372932 | 1
                               | 5027
                                         | 2014-12-02 | 广东
                               | 5027
| 225656 | 102865660 | 323237439 | 1
                                         | 2014-12-07 |山西
| 225657 | 102865660 | 323237439 | 1
                               | 5027
                                         | 2014-12-13 |内蒙古
| 225658 | 102865660 | 34102362 | 1
                               | 1863
                                         | 2014-11-26 | 湖北
                               | 12388
| 225659 | 102865660 | 373499226 | 1
                               | 5027
                                         | 2014-12-06 | 山西
| 225660 | 102865660 | 271583890 | 1
                                         | 2014-11-26 |澳门
                                | 5399
| 225661 | 102865660 | 384764083 | 1
                                | 5027
                                          2014-12-03 | 广东
225662 | 102865660 | 139671483 | 1
+----+
10 rows in set (0.00 sec)
```

切换到刚才已经打开的 R 命令提示符终端窗口,使用如下命令让 R 连接到 MySQL 数据库:

```
>library(RMySQL)
>conn<-
dbConnect(MySQL(),dbname='dblab',username='root',password='hadoop',host="127.0.0.1",
port=3306)
>user_action<-dbGetQuery(conn,'select * from user_action')</pre>
```

#### 2.分析消费者对商品的行为

summary()函数可以得到样本数据类型和长度,如果样本是数值型,还能得到样本数据的最小值、最大值、四分位数和均值信息。首先使用 summary()函数查看 MySQL 数据库中

表 user\_action 的字段 behavior\_type 的类型,命令如下:

```
> summary (user_action$behavior_type)
```

运行结果如下:

```
Length Class Mode
300000 character character
```

可以看出,原来的 MySQL 数据中,表 user\_action 的字段 behavior\_type 的类型是字符型。这样不方便做比较,需要把 behavior\_type 的字段类型转换为数值型,命令如下:

```
> summary(as.numeric(user_action$behavior_type))
```

该命令执行后会得到如下结果:

```
Min. 1st Qu. Median Mean 3rd Qu. Max.
1.000 1.000 1.000 1.105 1.000 4.000
```

接下来用柱状图展示消费者的行为类型的分布情况,命令如下:

```
>library(ggplot2)
>ggplot(user_action,aes(as.numeric(behavior_type)))+geom_histogram()
```

上面两行命令中:第一行 library(ggplot2)命令用来导入依赖库 ggplot2;第二行命令用于完成绘图。运行结果如图 12-7 所示。

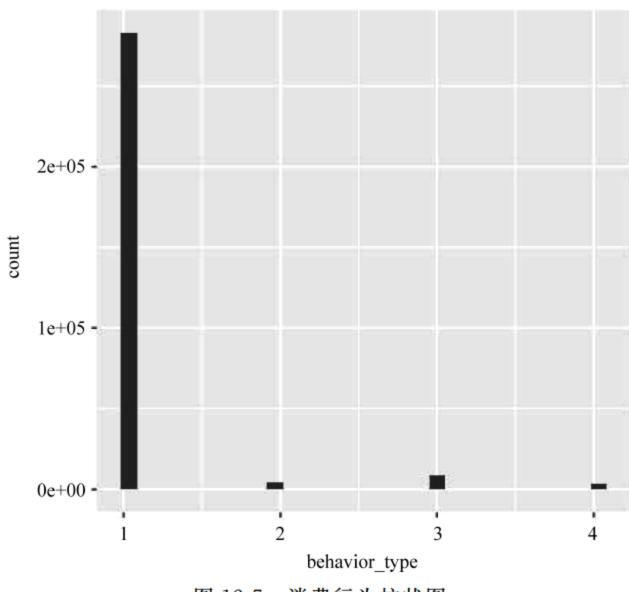


图 12-7 消费行为柱状图

从图 12-7 可以看出,大部分消费者行为仅仅只是浏览,只有很少部分的消费者会购买商品。

#### 3. 分析销量排名前十的商品及其销量

分析销量排名前十的商品及其销量,可以采用如下命令:

```
#获取子数据集
> temp<- subset (user_action, as.numeric (behavior_type) == 4)
> count<-sort(table(temp$item_category),decreasing=T)
                                                       #排序
                         #获取第 1~10 的排序结果
>print(count[1:10])
```

在上面的命令语句中,subset()函数用于从某一个数据集中选择出符合某条件的数据 或者相关的列。table()对应的就是统计学中的"列联表",是一种记录频数的方法。sort() 用来完成排序,返回排序后的数值向量。上述命令执行结果如下:

```
6344 1863
           5232 12189 7957 4370 13230 11537 1838
                                                     5894
           45
                  42
                                                      30
79
      46
                        40
                             34
                                    33
                                          32
                                                31
```

上面的执行结果中,第一行表示商品分类,第二行表示该类的销量。 接下来用散点图展示上面的分析结果,命令如下:

```
>result<-as.data.frame(count[1:10]) #将 count 矩阵结果转换成数据框
>ggplot(result, aes(Var1, Freq, col=factor(Var1)))+geom_point()
```

在上面的命令语句中,第一行命令通过 as. data. frame() 函数把矩阵转换成为数据框, 第二行命令完成散点图绘制。具体执行结果如图 12-8 所示。

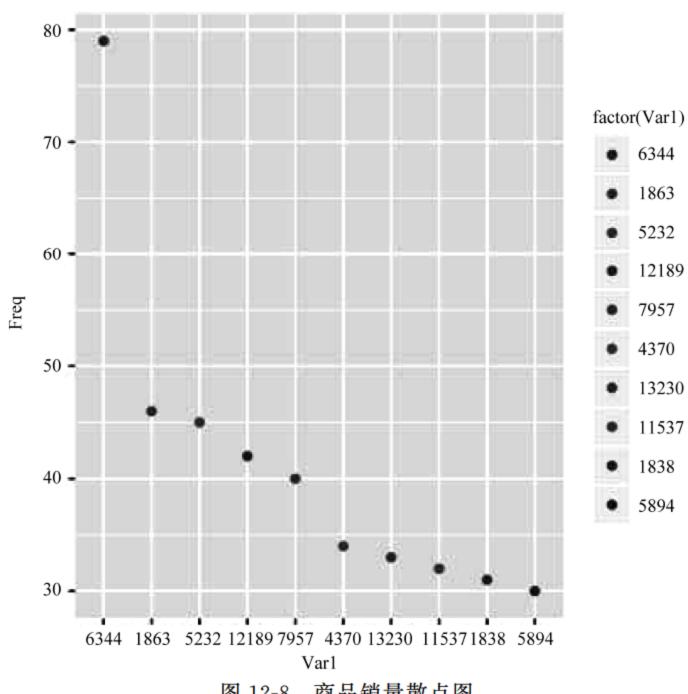


图 12-8 商品销量散点图

#### 4. 分析每年的哪个月份销量最大

从 MySQL 直接获取的数据中, visit\_date 变量都是 2014 年份,并没有划分出具体的月份,因此,需要在数据集中增加一列关于月份的数据,命令如下:

```
>month<-substr(user_action$visit_date,6,7) #visit_date变量中截取月份
>user_action<-cbind(user_action,month) #user_action增加一列月份数据
```

接下来用柱状图展示消费者在一年的不同月份的购买量情况,命令如下:

```
>ggplot(user_action,aes(as.numeric(behavior_type),col=factor(month)))+geom_histogram()+facet_grid(.~month)
```

在上面这条命令中,aes()函数中的 col 属性可以用来设置颜色。factor()函数则是把数值变量转换成分类变量,从而可以用不同的颜色表示。如果不使用 factor()函数,颜色将以同一种颜色渐变的颜色表现。facet\_grid(.~month)表示柱状图按照不同月份进行分区。由于本案例中,MySQL 获取的数据中只有 11 月份和 12 月份的数据,所以,执行结果中只会显示两个表格。上面命令的具体执行结果如图 12-9 所示。

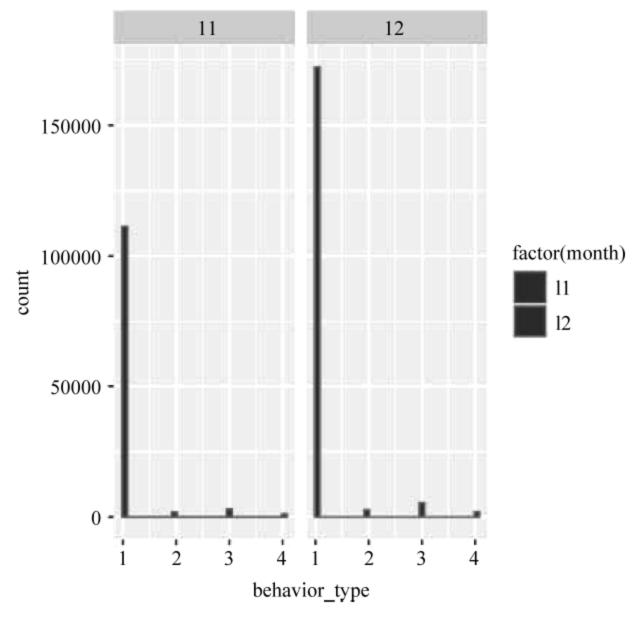


图 12-9 消费者购买量月份分布图

## 5. 分析国内哪个省份的消费者最有购买欲望

可以使用如下语句来分析国内各个省份的消费者的购买情况:

```
> library(recharts)
> rel<-as.data.frame(table(temp$province))
> provinces<-rel$Var1
> x=c()
> for (n in provinces) {
> x[length(x)+1]=nrow(subset(temp,(province==n)))
> }
> mapData<-data.frame(province=rel$Var1,count=x, stringsAsFactors=F)
#设置地图信息
> eMap(mapData, namevar=~province, datavar=~count) #画出中国地图
```

在上面的命令语句中,nrow()用来计算数据集的行数。

# 12.8 本章小结

综合实验案例是大数据技术体系学习的重要内容,可以帮助读者形成对大数据技术综合运用方法的全局性认识,让前面各个章节所学的技术有效融会贯通,通过多种技术的组合来解决实际应用问题。本章的综合实验案例涵盖了 Linux、MySQL、Hadoop、HBase、Hive、Sqoop、R、Eclipse 等系统和软件的安装和使用方法,这些软件的安装和使用方法,被有效融合到实验的各个流程,可以有效加深对各种技术的理解。

输入大量命令,系统会自动保存人们历史上输入的命令,可以按键盘上的"上箭头"和 "下箭头"按钮,翻看历史命令,找到某条历史命令后,可以直接按 Enter 键执行该命令,这 样,就不需要重复输入一些较长的命令了,大大节省了命令输入时间。

# 第 13 章

# 实 验

# 13.1 实验一:熟悉常用的 Linux 操作和 Hadoop 操作

本实验对应第3章的内容。

## 13.1.1 实验目的

Hadoop 运行在 Linux 系统上,因此,需要学习实践一些常用的 Linux 命令。本实验旨在熟悉常用的 Linux 操作和 Hadoop 操作,为顺利开展后续其他实验奠定基础。

## 13.1.2 实验平台

- (1) 操作系统: Linux(建议 Ubuntu 16.04)。
- (2) Hadoop 版本: 2.7.1。

#### 13.1.3 实验步骤

#### 1. 熟悉常用的 Linux 操作

- 1) cd 命令: 切换目录
- (1) 切换到目录/usr/local。
- (2) 切换到当前目录的上一级目录。
- (3) 切换到当前登录 Linux 系统的用户自己的主文件夹。
- 2) ls 命令: 查看文件与目录

查看目录/usr 下的所有文件和目录。

- 3) mkdir 命令:新建目录
- (1) 进入/tmp 目录,创建一个名为 a 的目录,并查看/tmp 目录下已经存在哪些目录。
- (2) 进入/tmp 目录,创建目录 a1/a2/a3/a4。
- 4) rmdir 命令: 删除空的目录
- (1) 将上面创建的目录 a(在/tmp 目录下面)删除。
- (2) 删除上面创建的目录 a1/a2/a3/a4(在/tmp 目录下面),然后查看/tmp 目录下面存在哪些目录。

- 5) cp 命令: 复制文件或目录
- (1) 将当前用户的主文件夹下的文件. bashrc 复制到目录/usr 下,并重命名为 bashrc1。
- (2) 在目录/tmp 下新建目录 test,再把这个目录复制到/usr 目录下。
- 6) mv 命令:移动文件与目录,或重命名
- (1) 将/usr 目录下的文件 bashrc1 移动到/usr/test 目录下。
- (2) 将/usr 目录下的 test 目录重命名为 test2。
- 7) rm 命令: 移除文件或目录
- (1) 将/usr/test2 目录下的 bashrc1 文件删除。
- (2) 将/usr 目录下的 test2 目录删除。
- 8) cat 命令: 查看文件内容 查看当前用户主文件夹下的. bashrc 文件的内容。
- 9) tac 命令: 反向查看文件内容 反向查看当前用户主文件夹下的. bashrc 文件的内容。
- 10) more 命令: 一页一页翻动查看 翻页查看当前用户主文件夹下的. bashrc 文件的内容。
- 11) head 命令: 取出前面几行
- (1) 查看当前用户主文件夹下. bashrc 文件的内容的前 20 行。
- (2) 查看当前用户主文件夹下. bashrc 文件的内容,后面 50 行不显示,只显示前面几行。
  - 12) tail 命令: 取出后面几行
  - (1) 查看当前用户主文件夹下. bashrc 文件的内容的最后 20 行。
  - (2) 查看当前用户主文件夹下. bashrc 文件的内容,并且只列出 50 行以后的数据。
  - 13) touch 命令: 修改文件时间或创建新文件
  - (1) 在/tmp 目录下创建一个空文件 hello,并查看文件时间。
  - (2) 修改 hello 文件,将文件时间调整为 5 天前。
  - 14) chown 命令:修改文件所有者的权限 将 hello 文件所有者改为 root 账号,并查看属性。
  - 15) find 命令: 文件查找 找出主文件夹下文件名为. bashrc 的文件。
  - 16) tar 命令: 压缩命令
  - (1) 在根目录/下新建文件夹 test,然后在根目录"/"下打包成 test. tar. gz。
  - (2) 把上面的 test. tar. gz 压缩包,解压缩到/tmp 目录。
  - 17) grep 命令: 查找字符串 从~/. bashrc 文件中查找字符串'examples'。

- 18) 配置环境变量
- (1) 请在~/. bashrc 中设置,配置 Java 环境变量。
- (2) 查看 JAVA\_HOME 变量的值。

#### 2. 熟悉常用的 Hadoop 操作

- (1) 使用 hadoop 用户登录 Linux 系统,启动 Hadoop(Hadoop 的安装目录为/usr/local/hadoop),为 hadoop 用户在 HDFS 中创建用户目录/user/hadoop。
  - (2) 接着在 HDFS 的目录/user/hadoop 下, 创建 test 文件夹,并查看文件列表。
  - (3) 将 Linux 系统本地的~/. bashrc 文件上传到 HDFS 的 test 文件夹中,并查看 test。
- (4) 将 HDFS 文件夹 test 复制到 Linux 系统本地文件系统的/usr/local/hadoop 目录下。

#### 13.1.4 实验报告

实验报告如表 13-1 所示。

表 13-1 实验报告

实验报告						
题目 姓名 日期						
实验环境:						
实验内容与完成情况:						
出现的问题:						
解决方案(列出遇到的问题和解决办法,列出没有解决的问题):						

注:实验答案请见附录 A。

# 13.2 实验二: 熟悉常用的 HDFS 操作

本实验对应第4章的内容。

## 13.2.1 实验目的

- (1) 理解 HDFS 在 Hadoop 体系结构中的角色。
- (2) 熟练使用 HDFS 操作常用的 shell 命令。
- (3) 熟悉 HDFS 操作常用的 Java API。

## 13.2.2 实验平台

- (1) 操作系统: Linux(建议 Ubuntu 16.04)。
- (2) Hadoop 版本: 2.7.1。
- (3) JDK 版本: 1.7 或以上版本。
- (4) Java IDE: Eclipse.

## 13.2.3 实验步骤

- (1) 编程实现以下功能,并利用 Hadoop 提供的 shell 命令完成相同任务。
- ① 向 HDFS 中上传任意文本文件,如果指定的文件在 HDFS 中已经存在,则由用户来 指定是追加到原有文件末尾还是覆盖原有的文件。
- ② 从 HDFS 中下载指定文件,如果本地文件与要下载的文件名称相同,则自动对下载的文件重命名。
  - ③ 将 HDFS 中指定文件的内容输出到终端中。
  - ④ 显示 HDFS 中指定的文件的读写权限、大小、创建时间、路径等信息。
- ⑤ 给定 HDFS 中某一个目录,输出该目录下的所有文件的读写权限、大小、创建时间、路径等信息,如果该文件是目录,则递归输出该目录下所有文件相关信息。
- ⑥ 提供一个 HDFS 内的文件的路径,对该文件进行创建和删除操作。如果文件所在目录不存在,则自动创建目录。
- ⑦ 提供一个 HDFS 的目录的路径,对该目录进行创建和删除操作。创建目录时,如果目录文件所在目录不存在,则自动创建相应目录;删除目录时,由用户指定当该目录不为空时是否还删除该目录。
  - ⑧ 向 HDFS 中指定的文件追加内容,由用户指定内容追加到原有文件的开头或结尾。
  - ⑨ 删除 HDFS 中指定的文件。
  - ⑩ 在 HDFS 中,将文件从源路径移动到目的路径。
- (2)编程实现一个类 MyFSDataInputStream,该类继承 org. apache. hadoop. fs. FSDataInputStream,要求如下:实现按行读取 HDFS 中指定文件的方法 readLine(),如果读到文件末尾,则返回空;否则,返回文件一行的文本。
- (3) 查看 Java 帮助手册或其他资料,用 java. net. URL 和 org. apache. hadoop. fs. FsURLStreamHandlerFactory 编程完成输出 HDFS 中指定文件的文本到终端中。

## 13.2.4 实验报告

实验报告如表 13-2 所示。

表 13-2 实验报告

实验报告						
题目 姓名 日期						
实验环境:						
实验内容与完成情况:						
出现的问题:						
解决方案(列出遇到的问题和解决办法,列出没有解决的问题):						

注:实验答案请见附录 A。

## 13.3 实验三: 熟悉常用的 HBase 操作

本实验对应第5章的内容。

## 13.3.1 实验目的

- (1) 理解 HBase 在 Hadoop 体系结构中的角色。
- (2) 熟练使用 HBase 操作常用的 Shell 命令。
- (3) 熟悉 HBase 操作常用的 Java API。

## 13.3.2 实验平台

- (1) 操作系统: Linux(建议 Ubuntu 16.04)。
- (2) Hadoop 版本: 2.7.1。
- (3) HBase 版本: 1.1.5。
- (4) JDK 版本: 1.7 或以上版本。
- (5) Java IDE: Eclipse.

## 13.3.3 实验步骤

- 1. 编程实现以下指定功能,并用 Hadoop 提供的 HBase Shell 命令完成相同任务
- (1) 列出 HBase 所有的表的相关信息,例如表名。
- (2) 在终端打印出指定的表的所有记录数据。
- (3) 向已经创建好的表添加和删除指定的列族或列。
- (4) 清空指定的表的所有记录数据。
- (5) 统计表的行数。

#### 2. HBase 数据库操作

(1) 现有以下关系型数据库中的表和数据(见表 13-3~表 13-5),要求将其转换为适合于 HBase 存储的表并插入数据。

学号(S_No)	姓名(S_Name)	性别(S_Sex)	年龄(S_Age)
2015001	Zhangsan	male	23
2015003	Mary	female	22
2015003	Lisi	male	24

表 13-3 学生表(Student)

课程号(C_No)	课程名(C_Name)	学分(C_Credit)
123001	Math	2.0
123002	Computer Science	5.0
123003	English	3.0

表 13-4 课程表(Course)

<b>±</b> •	~ =	洗课	=	(00)
<del></del>	4-5	77E 7#	ᆓ	

学号(SC_Sno)	课程号(SC_Cno)	成绩(SC_Score)
2015001	123001	86
2015001	123003	69
2015002	123002	77
2015002	123003	99
2015003	123001	98
2015003	123002	95

#### (2) 请编程实现以下功能。

① createTable(String tableName, String[] fields)。

创建表,参数 tableName 为表的名称,字符串数组 fields 为存储记录各个字段名称的数组。要求当 HBase 已经存在名为 tableName 的表的时候,先删除原有的表,然后再创建新的表。

② addRecord(String tableName, String row, String[] fields, String[] values)。

向表 tableName、行 row(用 S\_Name 表示)和字符串数组 fields 指定的单元格中添加对应的数据 values。其中, fields 中每个元素如果对应的列族下还有相应的列限定符,用 "columnFamily: column"表示。例如,同时向 Math、Computer Science、English 三列添加成绩时,字符串数组 fields 为{"Score: Math","Score: Computer Science",""Score: English"},数组 values 存储这三门课的成绩。

③ scanColumn(String tableName, String column)。

浏览表 tableName 某一列的数据,如果某一行记录中该列数据不存在,则返回 null。要求当参数 column 为某一列族名称时,如果底下有若干个列限定符,则要列出每个列限定符代表的列的数据;当参数 column 为某一列具体名称(例如"Score: Math")时,只需要列出该列的数据。

@ modifyData(String tableName, String row, String column).

修改表 tableName,即修改行 row(可以用学生姓名 S\_Name 表示)、列 column 指定的单元格的数据。

(5) deleteRow(String tableName, String row).

删除表 tableName 中 row 指定的行的记录。

## 13.3.4 实验报告

实验报告如表 13-6 所示。

表 13-6 实验报告

实验报告						
题目 姓名 日期						
实验环境:						
实验内容与完成情况:						
出现的问题:						
解决方案(列出遇到的问题和解决办法,列出没有解决的问题):						

注:实验答案请见附录 A。

# 13.4 实验四: NoSQL 和关系数据库的操作比较

本实验对应第6章的内容。

## 13.4.1 实验目的

- (1) 理解 4 种数据库(MySQL、HBase、Redis 和 MongoDB)的概念及不同点。
- (2) 熟练使用 4 种数据库操作常用的 Shell 命令。
- (3) 熟悉 4 种数据库操作常用的 Java API。

## 13.4.2 实验平台

- (1) 操作系统: Linux(建议 Ubuntu 16.04)。
- (2) Hadoop 版本: 2.7.1。
- (3) MySQL 版本: 5.6。
- (4) HBase 版本: 1.1.2。
- (5) Redis 版本: 3.0.6。
- (6) MongoDB 版本: 3.2.6。
- (7) JDK 版本: 1.7 或以上版本。
- (8) Java IDE: Eclipse.

## 13.4.3 实验步骤

## 1. MySQL 数据库操作

Student 表如表 13-7 所示。

表 13-7 Student 表

Name	English	Math	Computer
zhangsan	69	86	77
lisi	55	100	88

- (1) 根据上面给出的 Student 表,在 MySQL 数据库中完成如下操作。
- ① 在 MySQL 中创建 Student 表,并录入数据。
- ② 用 SQL 语句输出 Student 表中的所有记录。
- ③ 查询 zhangsan 的 Computer 成绩。
- ④ 修改 lisi 的 Math 成绩,改为 95。
- (2) 根据上面已经设计出的 Student 表,使用 MySQL 的 Java 客户端编程实现以下操作。
  - ① 向 Student 表中添加如下所示的一条记录:

Scotleid 45
-------------

② 获取 scofield 的 English 成绩信息。

#### 2. HBase 数据库操作

Student 表如表 13-8 所示。

表 13-8 Student 表

nama		score	
name	English	Math	Computer
zhangsan	69	86	77
lisi	55	100	88

- (1) 根据上面给出的 Student 表的信息,执行如下操作。
- ① 用 Hbase Shell 命令创建学生表 Student。
- ② 用 scan 命令浏览 Student 表的相关信息。
- ③ 查询 zhangsan 的 Computer 成绩。
- ④ 修改 lisi 的 Math 成绩,改为 95。
- (2) 根据上面已经设计出的 Student 表,用 HBase API 编程实现以下操作。
- ① 添加数据: English 为 45; Math 为 89; Computer 为 100。

② 获取 scofield 的 English 成绩信息。

#### 3. Redis 数据库操作

Student 键值对如下:

- (1) 根据上面给出的键值对,完成如下操作。
- ① 用 Redis 的哈希结构设计出学生表 Student(键值可以用 student. zhangsan 和 student. lisi 来表示两个键值属于同一个表)。
  - ② 用 hgetall 命令分别输出 zhangsan 和 lisi 的成绩信息。
  - ③ 用 hget 命令查询 zhangsan 的 Computer 成绩。
  - ④ 修改 lisi 的 Math 成绩,改为 95。
- (2) 根据上面已经设计出的学生表 Student,用 Redis 的 Java 客户端编程(jedis),实现如下操作。
- ① 添加数据: English 为 45; Math 为 89; Computer 为 100。该数据对应的键值对形式如下:

```
scofield:{
English: 45
Math: 89
Computer: 100
}
```

② 获取 scofield 的 English 成绩信息。

## 4. MongoDB 数据库操作

Student 文档如下:

```
{
    "name": "zhangsan",
    "score": {
        "English": 69,
        "Math": 86,
        "Computer": 77
}
```

```
"name": "lisi",
    "score": {
        "English": 55,
        "Math": 100,
        "Computer": 88
}
```

- (1) 根据上面给出的文档,完成如下操作。
- ① 用 MongoDB Shell 设计出 student 集合。
- ② 用 find()方法输出两个学生的信息。
- ③ 用 find()方法查询 zhangsan 的所有成绩(只显示 score 列)。
- ④ 修改 lisi 的 Math 成绩,改为 95。
- (2) 根据上面已经设计出的 Student 集合,用 MongoDB 的 Java 客户端编程,实现如下操作。
  - ① 添加数据: English 为 45; Math 为 89; Computer 为 100。

与上述数据对应的文档形式如下:

```
"name": "scofield",
    "score": {
        "English": 45,
        "Math": 89,
        "Computer": 100
    }
}
```

② 获取 scofield 的所有成绩成绩信息(只显示 score 列)。

## 13.4.4 实验报告

实验报告如表 13-9 所示。

表 13-9 实验报告

实验报告								
题目		姓名		日期				
实验环境:								
实验内容与完成情况:								
出现的问题:								
解决方案(列出遇到的问题和解决办法,列出没有解决的问题):								

# 13.5 实验五: MapReduce 初级编程实践

本实验对应第7章的内容。

## 13.5.1 实验目的

- (1) 通过实验掌握基本的 MapReduce 编程方法。
- (2) 掌握用 MapReduce 解决一些常见的数据处理问题,包括数据去重、数据排序和数据挖掘等。

## 13.5.2 实验平台

- (1) 操作系统: Linux(建议 Ubuntu 16.04)。
- (2) Hadoop 版本: 2.7.1。

## 13.5.3 实验步骤

## 1. 编程实现文件合并和去重操作

对于两个输入文件,即文件 A 和文件 B,编写 MapReduce 程序,对两个文件进行合并,并剔除其中重复的内容,得到一个新的输出文件 C。下面是输入文件和输出文件的一个样例供参考。

输入文件 A 的样例如下:

```
20170101 x

20170102 y

20170103 x

20170104 y

20170105 z

20170106 x
```

#### 输入文件 B 的样例如下:

```
20170101 y
20170102 y
20170103 x
20170104 z
20170105 y
```

根据输入文件 A 和 B 合并得到的输出文件 C 的样例如下:

```
20170101 x
20170101 y
```

```
20170102 y
20170103 x
20170104 y
20170105 y
20170105 z
20170106 x
```

#### 2. 编写程序实现对输入文件的排序

现在有多个输入文件,每个文件中的每行内容均为一个整数。要求读取所有文件中的整数,进行升序排序后,输出到一个新的文件中,输出的数据格式为每行两个整数,第一个数字为第二个整数的排序位次,第二个整数为原待排列的整数。下面是输入文件和输出文件的一个样例供参考。

输入文件1的样例如下:

```
33
37
12
40
```

输入文件 2 的样例如下:

```
4
16
39
5
```

输入文件3的样例如下:

```
1
45
25
```

根据输入文件 1、2 和 3 得到的输出文件如下:

```
1 1
2 4
3 5
4 12
5 16
6 25
```

```
7 33
8 37
9 39
10 40
11 45
```

## 3. 对给定的表格进行信息挖掘

下面给出一个 child-parent 的表格,要求挖掘其中的父子辈关系,给出祖孙辈关系的表格。

输入文件内容如下:

child	parent	
Steven	Lucy	
Steven	Jack	
Jone	Lucy	
Jone	Jack	
Lucy	Mary	
Lucy	Frank	
Jack	Alice	
Jack	Jesse	
David	Alice	
David	Jesse	
Philip	David	
Philip	Alma	
Mark	David	
Mark	Alma	

## 输出文件内容如下:

```
grandparent
grandchild
                 Alice
Steven
                 Jesse
Steven
                 Alice
Jone
                 Jesse
Jone
                 Mary
Steven
                 Frank
Steven
                 Mary
Jone
                 Frank
Jone
Philip
                 Alice
Philip
                 Jesse
Mark
                 Alice
Mark
                 Jesse
```

# 13.5.4 实验报告

实验报告如表 13-10 所示。

表 13-10 实验报告

实验报告								
题目		姓名		日期				
实验环境:								
解决问题的思路:								
实验内容与完成情况:								
出现的问题:								
解决方案(列出遇到的问题和解决办法,列出没有解决的问题):								

注:实验答案请见附录 A。

# 附录 A

# 大数据课程实验答案

本部分内容为本书相关章节实验题目的答案,仅供参考,包含了以下5个实验的答案。

- (1) 实验一: 熟悉常用的 Linux 操作和 Hadoop 操作。
- (2) 实验二: 熟悉常用的 HDFS 操作。
- (3) 实验三: 熟悉常用的 HBase 操作。
- (4) 实验四: NoSQL 和关系数据库的操作比较。
- (5) 实验五: MapReduce 初级编程实践。

为了方便读者直接使用答案中的代码,本书官网"下载专区"的"实验答案"目录下,提供了附录 A 内容的电子书。

# A. 1 实验一: 熟悉常用的 Linux 操作和 Hadoop 操作

本实验对应第3章的内容。

## A.1.1 实验目的

Hadoop 运行在 Linux 系统上,因此,需要学习实践一些常用的 Linux 命令。本实验旨在熟悉常用的 Linux 操作和 Hadoop 操作,为顺利开展后续其他实验奠定基础。

## A.1.2 实验平台

- (1) 操作系统: Linux(建议 Ubuntu 16.04)。
- (2) Hadoop 版本: 2.7.1。

## A.1.3 实验步骤

- 1. 熟悉常用的 Linux 操作
- 1) cd 命令: 切换目录
- (1) 切换到目录/usr/local。

\$cd /usr/local

(2) 切换到当前目录的上一级目录。

\$cd ..

(3) 切换到当前登录 Linux 系统的用户的自己的主文件夹。

\$cd ~

2) ls 命令: 查看文件与目录 查看目录/usr 下的所有文件和目录。

\$cd /usr \$ls -al

- 3) mkdir 命令: 新建目录
- (1) 进入/tmp 目录,创建一个名为 a 的目录,并查看/tmp 目录下已经存在哪些目录。

\$cd /tmp

\$mkdir a

\$ls -al

(2) 进入/tmp 目录,创建目录 a1/a2/a3/a4。

\$cd /tmp
\$mkdir-p a1/a2/a3/a4

- 4) rmdir 命令: 删除空的目录
- (1) 将上面创建的目录 a(在/tmp 目录下面)删除。

\$cd /tmp

\$rmdir a

(2) 删除上面创建的目录 a1/a2/a3/a4(在/tmp 目录下面),然后查看/tmp 目录下面存在哪些目录。

\$cd /tmp

\$rmdir-p a1/a2/a3/a4

\$ls -al

- 5) cp 命令: 复制文件或目录
- (1) 将当前用户的主文件夹下的文件. bashrc 复制到目录/usr 下,并重命名为 bashrc1。

\$sudo cp ~/.bashrc /usr/bashrc1

(2) 在目录/tmp 下新建目录 test,再把这个目录复制到/usr 目录下。

\$cd /tmp

\$mkdir test

\$sudo cp - r /tmp/test /usr

- 6) mv 命令:移动文件与目录,或重命名
- (1) 将/usr 目录下的文件 bashrc1 移动到/usr/test 目录下。

\$sudo mv /usr/bashrc1 /usr/test

(2) 将/usr 目录下的 test 目录重命名为 test2。

\$sudo mv /usr/test /usr/test2

- 7) rm 命令: 移除文件或目录
- (1) 将/usr/test2 目录下的 bashrc1 文件删除。

\$sudo rm /usr/test2/bashrc1

(2) 将/usr 目录下的 test2 目录删除。

\$sudo rm - r /usr/test2

8) cat 命令: 查看文件内容 查看当前用户主文件夹下的. bashrc 文件的内容。

\$cat ~/.bashrc

9) tac 命令: 反向查看文件内容 反向查看当前用户主文件夹下的. bashrc 文件的内容。

\$tac ~/.bashrc

10) more 命令: 一页一页翻动查看 翻页查看当前用户主文件夹下的. bashrc 文件的内容。

\$more ~/.bashrc

- 11) head 命令: 取出前面几行
- (1) 查看当前用户主文件夹下. bashrc 文件的内容的前 20 行。

\$head -n 20 ~/.bashrc

(2) 查看当前用户主文件夹下. bashrc 文件的内容,后面 50 行不显示,只显示前面几行。

 $head - n - 50 \sim leasher$ 

- 12) tail 命令: 取出后面几行
- (1)查看当前用户主文件夹下. bashrc 文件的内容的最后 20 行。

\$tail -n 20 ~/.bashrc

(2) 查看当前用户主文件夹下. bashrc 文件的内容,并且只列出 50 行以后的数据。

 $tail - n + 50 \sim /.bashrc$ 

- 13) touch 命令: 修改文件时间或创建新文件
- (1) 在/tmp 目录下创建一个空文件 hello,并查看文件时间。

\$cd /tmp

\$touch hello

\$1s -1 hello

(2) 修改 hello 文件,将文件时间调整为 5 天前。

\$touch -d "5 days ago" hello

14) chown 命令:修改文件所有者权限 将 hello 文件所有者改为 root 账号,并查看属性。

\$sudo chown root /tmp/hello \$ls - 1 /tmp/hello

15) find 命令: 文件查找 找出主文件夹下文件名为. bashrc 的文件。

\$find ~ - name .bashrc

- 16) tar 命令: 压缩命令
- (1) 在根目录"/"下新建文件夹 test,然后在根目录"/"下打包成 test. tar. gz。

\$sudo mkdir /test

\$sudo tar - zcv - f /test.tar.gz test

(2) 把上面的 test. tar. gz 压缩包,解压缩到/tmp 目录。

\$sudo tar - zxv - f /test.tar.gz - C /tmp

17) grep 命令: 查找字符串

从~/. bashrc 文件中查找字符串'examples'。

\$grep - n 'examples' ~/.bashrc

- 18) 配置环境变量
- (1) 请在~/. bashrc 中设置,配置 Java 环境变量。 首先使用 vim 编辑器打开文件~/. bashrc,命令如下:

\$vim ~/.bashrc

然后在该文件的最上面加入一行如下形式的语句:

export JAVA\_HOME=JDK安装路径

最后执行如下命令使得环境变量配置生效:

\$source ~/.bashrc

(2) 查看 JAVA\_HOME 变量的值。

\$echo \$JAVA\_HOME

#### 2. 熟悉常用的 Hadoop 操作

(1) 使用 hadoop 用户登录 Linux 系统,启动 Hadoop(Hadoop 的安装目录为/usr/local/hadoop),为 hadoop 用户在 HDFS 中创建用户目录/user/hadoop。

\$cd /usr/local/hadoop

- \$./sbin/start-dfs.sh
- \$./bin/hdfs dfs -mkdir -p /user/hadoop
- (2) 接着在 HDFS 的目录/user/hadoop 下,创建 test 文件夹,并查看文件列表。

\$cd /usr/local/hadoop

- \$./bin/hdfs dfs -mkdir test
- \$./bin/hdfs dfs ls .
- (3) 将 Linux 系统本地的~/. bashrc 文件上传到 HDFS 的 test 文件夹中,并查看 test。

\$cd /usr/local/hadoop

- \$./bin/hdfs dfs put ~/.bashrc test
- \$./bin/hdfs dfs ls test
- (4) 将 HDFS 文件夹 test 复制到 Linux 系统本地文件系统的/usr/local/hadoop 目录下。

\$cd /usr/local/hadoop

\$./bin/hdfs dfs - get test ./

## A. 2 实验二: 熟悉常用的 HDFS 操作

本实验对应第4章的内容。

## A. 2.1 实验目的

- (1) 理解 HDFS 在 Hadoop 体系结构中的角色。
- (2) 熟练使用 HDFS 操作常用的 Shell 命令。
- (3) 熟悉 HDFS 操作常用的 Java API。

#### A. 2. 2 实验平台

- (1) 操作系统: Linux(建议 Ubuntu 16.04)。
- (2) Hadoop 版本: 2.7.1。
- (3) JDK 版本: 1.7 或以上版本。
- (4) Java IDE: Eclipse.

## A. 2.3 实验步骤

- (1) 编程实现以下功能,并利用 Hadoop 提供的 Shell 命令完成相同任务。
- ① 向 HDFS 中上传任意文本文件,如果指定的文件在 HDFS 中已经存在,则由用户来指定是追加到原有文件末尾还是覆盖原有的文件。
  - a. Shell 命令。

检查文件是否存在,可以使用如下命令:

\$cd /usr/local/hadoop

\$./bin/hdfs dfs - test - e text.txt

执行完上述命令不会输出结果,需要继续输入命令查看结果:

\$echo \$?

如果结果显示文件已经存在,则用户可以选择追加到原来文件末尾或者覆盖原来文件, 具体命令如下:

```
$cd /usr/local/hadoop
$./bin/hdfs dfs - appendToFile local.txt text.txt #追加到原文件末尾
$./bin/hdfs dfs - copyFromLocal - f local.txt text.txt #覆盖原来文件,第一种命令形式
$./bin/hdfs dfs - cp - f file:///home/hadoop/local.txt text.txt
#覆盖原来文件,第二种命令形式
```

实际上也可以不用上述方式,而是采用如下命令来实现:

```
$if $(hdfs dfs-test-e text.txt);
$then $(hdfs dfs-appendToFile local.txt text.txt);
$else $(hdfs dfs-copyFromLocal-f local.txt text.txt);
$fi
```

上述代码可视为一行代码,在终端中输入第一行代码后,代码不会立即被执行,可以继续输入第2行代码和第3行代码,直到输入 fi 以后,上述代码才会真正执行。另外,上述代码中直接使用了 hdfs 命令,而没有给出命令的路径,因为,这里假设已经配置了 PATH 环境变量,把 hdfs 命令的路径/usr/local/hadoop/bin 写入了 PATH 环境变量中。

b. Java 代码。

```
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.*;
import java.io.*;

public class HDFSApi {
    /**
    * 判断路径是否存在
    * /
    public static boolean test(Configuration conf, String path) throws IOException {
        FileSystem fs=FileSystem.get(conf);
        return fs.exists(new Path(path));
    }

/**
    * 复制文件到指定路径
    * 者路径已存在,则进行覆盖
    * /
    public static void copyFromLocalFile (Configuration conf, String localFilePath, String remoteFilePath) throws IOException {
```

```
FileSystem fs=FileSystem.get(conf);
       Path localPath=new Path (localFilePath);
       Path remotePath=new Path (remoteFilePath);
       /* fs.copyFromLocalFile 第一个参数表示是否删除源文件,第二个参数表示是否覆
           盖 * /
       fs.copyFromLocalFile(false, true, localPath, remotePath);
       fs.close();
    /**
    * 追加文件内容
    * /
    public static void appendToFile (Configuration conf, String localFilePath, String
    remoteFilePath) throws IOException {
       FileSystem fs=FileSystem.get(conf);
       Path remotePath=new Path (remoteFilePath);
       /* 创建一个文件读入流 */
       FileInputStream in=new FileInputStream(localFilePath);
       /* 创建一个文件输出流,输出的内容将追加到文件末尾 */
       FSDataOutputStream out=fs.append(remotePath);
       /*读写文件内容 */
       byte[] data=new byte[1024];
       int read=-1;
       while((read=in.read(data))>0) {
           out.write(data, 0, read);
       out.close();
       in.close();
       fs.close();
   /**
    * 主函数
    * /
   public static void main(String[] args) {
       Configuration conf=new Configuration();
   conf.set("fs.default.name", "hdfs://localhost:9000");
                                                     //本地路径
       String localFilePath="/home/hadoop/text.txt";
                                                     //HDFS 路径
       String remoteFilePath="/user/hadoop/text.txt";
                                  //若文件存在则追加到文件末尾
       String choice= "append";
                                  //若文件存在则覆盖
//
       String choice= "overwrite";
       try {
               /* 判断文件是否存在 */
```

```
Boolean fileExists=false;
                if(HDFSApi.test(conf, remoteFilePath)) {
                fileExists=true;
                System.out.println(remoteFilePath+"已存在.");
            } else {
                System.out.println(remoteFilePath+"不存在.");
            /* 进行处理 */
            if(!fileExists) { //文件不存在,则上传
                HDFSApi.copyFromLocalFile(conf, localFilePath, remoteFilePath);
                System.out.println(localFilePath+"已上传至 "+remoteFilePath);
            } else if (choice.equals("overwrite")) {
                                                     //选择覆盖
              HDFSApi.copyFromLocalFile(conf, localFilePath, remoteFilePath);
                System.out.println(localFilePath+"已覆盖"+remoteFilePath);
            } else if (choice.equals("append")) {
                HDFSApi.appendToFile(conf, localFilePath, remoteFilePath);
                System.out.println(localFilePath+"已追加至"+remoteFilePath);
        } catch (Exception e) {
            e.printStackTrace();
}
```

- ② 从 HDFS 中下载指定文件,如果本地文件与要下载的文件名称相同,则自动对下载的文件重命名。
  - a. Shell 命令。

```
$if $ (hdfs dfs - test - e file:///home/hadoop/text.txt);
$then $ (hdfs dfs - copyToLocal text.txt ./text2.txt);
$else $ (hdfs dfs - copyToLocal text.txt ./text.txt);
$fi
```

b. Java 代码。

```
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.*;
import java.io.*;

public class HDFSApi {
    /**
    *下载文件到本地
    *判断本地路径是否已存在,若已存在,则自动进行重命名
    */
```

```
public static void copyToLocal (Configuration conf, String remoteFilePath, String
    localFilePath) throws IOException {
       FileSystem fs=FileSystem.get(conf);
        Path remotePath=new Path (remoteFilePath);
        File f=new File(localFilePath);
       /*如果文件名存在,自动重命名(在文件名后面加上_0,_1 …)*/
        if(f.exists()) {
            System.out.println(localFilePath+"已存在.");
            Integer i=0;
           while (true) {
                f=new File(localFilePath+" "+i.toString());
                if(!f.exists()) {
                    localFilePath= localFilePath+ "_"+ i.toString();
                    break;
           System.out.println("将重新命名为: "+localFilePath);
       //下载文件到本地
        Path localPath=new Path (localFilePath);
        fs.copyToLocalFile(remotePath, localPath);
        fs.close();
    /**
     * 主函数
   public static void main(String[] args) {
       Configuration conf=new Configuration();
        conf.set("fs.default.name", "hdfs://localhost:9000");
                                                       //本地路径
        String localFilePath="/home/hadoop/text.txt";
        String remoteFilePath="/user/hadoop/text.txt";
                                                       //HDFS 路径
        try {
           HDFSApi.copyToLocal(conf, remoteFilePath, localFilePath);
           System.out.println("下载完成");
        } catch (Exception e) {
           e.printStackTrace();
}
```

a. Shell 命令。

```
$hdfs dfs -cat text.txt
```

#### b. Java 代码。

```
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.*;
import java.io.*;
public class HDFSApi {
    /**
     * 读取文件内容
     * /
    public static void cat (Configuration conf, String remoteFilePath) throws IOException {
        FileSystem fs=FileSystem.get(conf);
        PathremotePath = new Path (remoteFilePath);
        FSDataInputStream in=fs.open(remotePath);
        BufferedReader d= new BufferedReader (new InputStreamReader (in));
        String line=null;
        while ((line=d.readLine()) !=null) {
            System.out.println(line);
        }
        d.close();
        in.close();
        fs.close();
    /**
     * 主函数
    public static void main(String[] args) {
        Configuration conf=new Configuration();
        conf.set("fs.default.name", "hdfs://localhost:9000");
                                                           //HDFS 路径
        String remoteFilePath="/user/hadoop/text.txt";
        try {
            System.out.println("读取文件: "+remoteFilePath);
            HDFSApi.cat(conf, remoteFilePath);
            System.out.println("\n读取完成");
        } catch (Exception e) {
            e.printStackTrace();
```

④ 显示 HDFS 中指定的文件的读写权限、大小、创建时间、路径等信息。

a. Shell 命令。

```
$hdfs dfs -ls -h text.txt
```

#### b. Java 代码。

```
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.*;
import java.io.*;
import java.text.SimpleDateFormat;
public class HDFSApi {
    /**
     *显示指定文件的信息
     * /
    public static void ls (Configuration conf, String remoteFilePath) throws IOException {
        FileSystem fs=FileSystem.get(conf);
        Path remotePath=new Path (remoteFilePath);
        FileStatus[] fileStatuses=fs.listStatus(remotePath);
        for (FileStatus s : fileStatuses) {
            System.out.println("路径: "+s.getPath().toString());
            System.out.println("权限: "+s.getPermission().toString());
            System.out.println("大小: "+s.getLen());
            /* 返回的是时间戳,转化为时间日期格式 */
            Long timeStamp=s.getModificationTime();
            SimpleDateFormat format=new SimpleDateFormat ("yyyy-MM-dd HH:mm:ss");
            String date=format.format(timeStamp);
            System.out.println("时间:"+date);
        fs.close();
    /**
     * 主函数
     * /
    public static void main(String[] args) {
        Configuration conf=new Configuration();
        conf.set("fs.default.name", "hdfs://localhost:9000");
        String remoteFilePath="/user/hadoop/text.txt";
                                                         //HDFS 路径
        try {
            System.out.println("读取文件信息: "+ remoteFilePath);
```

```
HDFSApi.ls(conf, remoteFilePath);
System.out.println("\n读取完成");
} catch (Exception e) {
    e.printStackTrace();
}
}
```

- ⑤ 给定 HDFS 中某一个目录,输出该目录下的所有文件的读写权限、大小、创建时间、路径等信息,如果该文件是目录,则递归输出该目录下所有文件相关信息。
  - a. Shell 命令。

```
$cd /usr/local/hadoop
$./bin/hdfs dfs - ls - R - h /user/hadoop
```

```
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs. *;
import java.io.*;
import java.text.SimpleDateFormat;
public class HDFSApi {
     *显示指定文件夹下所有文件的信息(递归)
     * /
   public static void lsDir (Configuration conf, String remoteDir) throws IOException {
        FileSystem fs=FileSystem.get(conf);
        Path dirPath=new Path (remoteDir);
        /*递归获取目录下的所有文件 */
        RemoteIterator< LocatedFileStatus> remoteIterator= fs.listFiles
        (dirPath, true);
        /*输出每个文件的信息 */
        while (remoteIterator.hasNext()) {
            FileStatus s=remoteIterator.next();
            System.out.println("路径: "+s.getPath().toString());
            System.out.println("权限: "+s.getPermission().toString());
            System.out.println("大小: "+s.getLen());
            /* 返回的是时间戳,转化为时间日期格式 */
           Long timeStamp=s.getModificationTime();
            SimpleDateFormat format=new SimpleDateFormat ("yyyy-MM-dd HH:mm:ss");
            String date=format.format(timeStamp);
            System.out.println("时间: "+date);
```

```
System.out.println();
        fs.close();
    /**
     * 主函数
     * /
   public static void main(String[] args) {
       Configuration conf=new Configuration();
        conf.set("fs.default.name", "hdfs://localhost:9000");
                                           //HDFS 路径
        String remoteDir="/user/hadoop";
       try {
            System.out.println("(递归)读取目录下所有文件的信息: "+remoteDir);
           HDFSApi.lsDir(conf, remoteDir);
            System.out.println("读取完成");
        } catch (Exception e) {
            e.printStackTrace();
}
```

- ⑥ 提供一个 HDFS 内的文件的路径,对该文件进行创建和删除操作。如果文件所在目录不存在,则自动创建目录。
  - a. Shell 命令。

```
$if $(hdfs dfs-test-d dir1/dir2);
$then $(hdfs dfs-touchz dir1/dir2/filename);
$else $(hdfs dfs-mkdir-p dir1/dir2 && hdfs dfs-touchz dir1/dir2/filename);
$fi
$hdfs dfs-rm dir1/dir2/filename #删除文件
```

```
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.*;
import java.io.*;

public class HDFSApi {
    /**
    *判断路径是否存在
    */
    public static boolean test(Configuration conf, String path) throws
    IOException {
```

```
FileSystem fs=FileSystem.get(conf);
    return fs.exists (new Path (path));
/**
 * 创建目录
 * /
public static boolean mkdir (Configuration conf, String remoteDir) throws IOException {
    FileSystem fs=FileSystem.get(conf);
    Path dirPath=new Path (remoteDir);
    boolean result=fs.mkdirs(dirPath);
    fs.close();
    return result;
/**
 * 创建文件
 * /
 public static void touchz (Configuration conf, String remoteFilePath) throws
 IOException {
    FileSystem fs=FileSystem.get(conf);
    Path remotePath=new Path (remoteFilePath);
    FSDataOutputStream outputStream=fs.create(remotePath);
    outputStream.close();
    fs.close();
/**
 * 删除文件
 * /
public static boolean rm (Configuration conf, String remoteFilePath) throws IOException
    FileSystem fs=FileSystem.get(conf);
    Path remotePath=new Path (remoteFilePath);
    boolean result=fs.delete(remotePath, false);
    fs.close();
    return result;
/**
 * 主函数
 * /
public static void main(String[] args) {
```

```
Configuration conf=new Configuration();
       conf.set("fs.default.name", "hdfs://localhost:9000");
                                                            //HDFS 路径
       String remoteFilePath="/user/hadoop/input/text.txt";
                                                //HDFS 路径对应的目录
       String remoteDir="/user/hadoop/input";
       try {
           /* 判断路径是否存在,存在则删除,否则进行创建 */
           if(HDFSApi.test(conf, remoteFilePath)) {
               HDFSApi.rm(conf, remoteFilePath);
                                                //删除
               System.out.println("删除路径:"+remoteFilePath);
           } else {
               if(!HDFSApi.test(conf, remoteDir)) { //若目录不存在,则进行创建
                   HDFSApi.mkdir(conf, remoteDir);
                   System.out.println("创建文件夹:"+remoteDir);
               HDFSApi.touchz(conf, remoteFilePath);
               System.out.println("创建路径:"+remoteFilePath);
       } catch (Exception e) {
           e.printStackTrace();
}
```

⑦ 提供一个 HDFS 的目录的路径,对该目录进行创建和删除操作。创建目录时,如果目录文件所在目录不存在,则自动创建相应目录;删除目录时,由用户指定当该目录不为空时是否还删除该目录。

a. Shell 命令。

创建目录的命令如下:

```
$hdfs dfs -mkdir -p dir1/dir2
```

删除目录的命令如下:

```
$hdfs dfs - rmdir dir1/dir2
```

上述命令执行以后,如果目录非空,则会提示 not empty,删除操作不会执行。如果要强制删除目录,可以使用如下命令:

```
$hdfs dfs -rm -R dir1/dir2
```

```
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.*;
import java.io.*;
public class HDFSApi {
    /**
     * 判断路径是否存在
     * /
    public static boolean test (Configuration conf, Stringpath) throws
    IOException {
        FileSystem fs=FileSystem.get(conf);
        return fs.exists (new Path (path));
    /**
     * 判断目录是否为空
     * true:空;false:非空
     * /
     public static boolean isDirEmpty (Configuration conf, String remoteDir) throws
     IOException {
        FileSystem fs=FileSystem.get(conf);
        Path dirPath=new Path (remoteDir);
        RemoteIterator<LocatedFileStatus>remoteIterator=fs.listFiles
        (dirPath, true);
        return !remoteIterator.hasNext();
    /**
    * 创建目录
     * /
    public static boolean mkdir (Configuration conf, String remoteDir) throws IOException {
        FileSystem fs=FileSystem.get(conf);
        Path dirPath=new Path (remoteDir);
        boolean result=fs.mkdirs(dirPath);
        fs.close();
        return result;
    /**
     * 删除目录
     * /
    public static boolean rmDir (Configuration conf, String remoteDir) throws IOException {
```

```
FileSystem fs=FileSystem.get(conf);
    Path dirPath=new Path (remoteDir);
/* 第二个参数表示是否递归删除所有文件 */
   boolean result=fs.delete(dirPath, true);
    fs.close();
    return result;
/**
 * 主函数
 * /
public static void main(String[] args) {
    Configuration conf=new Configuration();
    conf.set("fs.default.name", "hdfs://localhost:9000");
    String remoteDir="/user/hadoop/input";
                                          //HDFS 目录
                                             //是否强制删除
    Boolean forceDelete=false;
    try {
       /* 判断目录是否存在,不存在则创建,存在则删除 */
       if(!HDFSApi.test(conf, remoteDir)) {
                                             //创建目录
           HDFSApi.mkdir(conf, remoteDir);
           System.out.println("创建目录: "+remoteDir);
        } else {
           if(HDFSApi.isDirEmpty(conf, remoteDir) || forceDelete) {
                                             //目录为空或强制删除
               HDFSApi.rmDir(conf, remoteDir);
               System.out.println("删除目录:"+remoteDir);
                         //目录不为空
           } else {
               System.out.println("目录不为空,不删除: "+remoteDir);
        }
    } catch (Exception e) {
       e.printStackTrace();
```

⑧ 向 HDFS 中指定的文件追加内容,由用户指定内容追加到原有文件的开头或结尾。 a. Shell 命令。

追加到原文件末尾的命令如下:

```
$hdfs dfs - appendToFile local.txt text.txt
```

追加到原文件的开头,在 HDFS 中不存在与这种操作对应的命令,因此,无法使用一条

命令来完成。可以先移动到本地进行操作,再进行上传覆盖,具体命令如下:

```
$hdfs dfs - get text.txt
$cat text.txt >> local.txt
$hdfs dfs - copyFromLocal - f text.txt text.txt
```

```
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.*;
import java.io.*;
public class HDFSApi {
    /**
     * 判断路径是否存在
     * /
    public static boolean test (Configuration conf, String path) throws
    IOException {
        FileSystem fs=FileSystem.get(conf);
        return fs.exists(new Path(path));
    /**
     * 追加文本内容
     * /
    public static void appendContentToFile(Configuration conf, String
    content, String remoteFilePath) throws IOException {
        FileSystem fs=FileSystem.get(conf);
        Path remotePath=new Path (remoteFilePath);
        /* 创建一个文件输出流,输出的内容将追加到文件末尾 */
        FSDataOutputStream out=fs.append(remotePath);
        out.write(content.getBytes());
        out.close();
        fs.close();
    /**
     * 追加文件内容
     * /
    public static void appendToFile (Configuration conf, String localFilePath, String
    remoteFilePath) throws IOException {
        FileSystem fs=FileSystem.get(conf);
        Path remotePath=new Path (remoteFilePath);
        /* 创建一个文件读入流 */
```

```
FileInputStream in=new FileInputStream(localFilePath);
    /* 创建一个文件输出流,输出的内容将追加到文件末尾 */
    FSDataOutputStream out=fs.append(remotePath);
    /*读写文件内容 */
   byte[] data=new byte[1024];
    int read=-1;
    while ((read=in.read(data))>0) {
        out.write(data, 0, read);
    }
    out.close();
    in.close();
    fs.close();
/**
 * 移动文件到本地
 * 移动后删除源文件
 * /
public static void moveToLocalFile (Configuration conf, String
remoteFilePath, String localFilePath) throws IOException {
    FileSystem fs=FileSystem.get(conf);
    Path remotePath=new Path (remoteFilePath);
    Path localPath=new Path (localFilePath);
    fs.moveToLocalFile(remotePath, localPath);
/**
 * 创建文件
 public static void touchz (Configuration conf, String remoteFilePath) throws
 IOException {
    FileSystem fs=FileSystem.get(conf);
    Path remotePath=new Path (remoteFilePath);
    FSDataOutputStream outputStream=fs.create(remotePath);
    outputStream.close();
    fs.close();
/**
 * 主函数
 * /
public static void main(String[] args) {
    Configuration conf=new Configuration();
    conf.set("fs.default.name", "hdfs://localhost:9000");
```

```
//HDFS 文件
       String remoteFilePath="/user/hadoop/text.txt";
       String content="新追加的内容\n";
                                                  //追加到文件末尾
       String choice= "after";
                                                  //追加到文件开头
       String choice= "before";
       try {
           /* 判断文件是否存在 */
           if(!HDFSApi.test(conf, remoteFilePath)) {
              System.out.println("文件不存在: "+remoteFilePath);
           } else {
                                                 //追加在文件末尾
              if(choice.equals("after")) {
                  HDFSApi.appendContentTbFile(conf, content, remoteFilePath);
                  System.out.println("已追加内容到文件末尾"+remoteFilePath);
              } else if (choice.equals("before")) { //追加到文件开头
                  /* 没有相应的 API 可以直接操作,因此先把文件移动到本地 * /
                  /* 创建一个新的 HDFS,再按顺序追加内容 */
                  String localTmpPath="/user/hadoop/tmp.txt";
                  //移动到本地
                  HDFSApi.moveTbLocalFile(conf, remoteFilePath, localTmpPath);
                  //创建一个新文件
                  HDFSApi.touchz(conf, remoteFilePath);
                  //先写入新内容
                  HDFSApi.appendContentTbFile(conf, content, remoteFilePath);
                  //再写入原来内容
                  HDFSApi.appendToFile(conf, localTmpPath, remoteFilePath);
                  System.out.println("已追加内容到文件开头:"+remoteFilePath);
           }
       } catch (Exception e) {
           e.printStackTrace();
}
```

- ⑨ 删除 HDFS 中指定的文件。
- a. Shell 命令。

```
$hdfs dfs - rm text.txt
```

```
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.*;
```

```
import java.io.*;
public class HDFSApi {
    /**
     * 删除文件
     * /
    public static boolean rm (Configuration conf, String remoteFilePath) throws IOException
        FileSystem fs=FileSystem.get(conf);
        Path remotePath=new Path (remoteFilePath);
        boolean result=fs.delete(remotePath, false);
        fs.close();
        return result;
    /**
     * 主函数
     * /
    public static void main(String[] args) {
        Configuration conf=new Configuration();
    conf.set("fs.default.name", "hdfs://localhost:9000");
                                                        //HDFS文件
        String remoteFilePath="/user/hadoop/text.txt";
        try {
            if(HDFSApi.rm(conf, remoteFilePath)) {
                System.out.println("文件删除: "+remoteFilePath);
            } else {
                System.out.println("操作失败(文件不存在或删除失败)");
        } catch (Exception e) {
            e.printStackTrace();
}
```

- ⑩ 在 HDFS 中,将文件从源路径移动到目的路径。
- a. Shell 命令。

```
$hdfs dfs -mv text.txt text2.txt
```

```
importorg.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.*;
```

```
import java.io.*;
public class HDFSApi {
    /**
     * 移动文件
     * /
   public static boolean mv (Configuration conf, String remoteFilePath,
   String remoteToFilePath) throws IOException {
        FileSystem fs=FileSystem.get(conf);
        Path srcPath=new Path (remoteFilePath);
        Path dstPath=new Path (remoteToFilePath);
        boolean result=fs.rename(srcPath, dstPath);
        fs.close();
        return result;
    /**
     * 主函数
     * /
   public static void main(String[] args) {
        Configuration conf=new Configuration();
        conf.set("fs.default.name", "hdfs://localhost:9000");
                                                                    //源文件 HDFS 路径
        String remoteFilePath="hdfs:///user/hadoop/text.txt";
                                                                      //目的 HDFS 路径
        String remoteToFilePath= "hdfs:///user/hadoop/new.txt";
        try {
            if(HDFSApi.mv(conf, remoteFilePath, remoteToFilePath)) {
                System.out.println("将文件 "+remoteFilePath+" 移动到 "+
                remoteToFilePath);
            } else {
                System.out.println("操作失败(源文件不存在或移动失败)");
            }
        } catch (Exception e) {
            e.printStackTrace();
}
```

(2)编程实现一个类 MyFSDataInputStream,该类继承 org. apache. hadoop. fs. FSDataInputStream,要求如下:实现按行读取 HDFS 中指定文件的方法 readLine(),如果读到文件末尾,则返回空;否则,返回文件一行的文本。

```
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.FSDataInputStream;
import org.apache.hadoop.fs.FileSystem;
import org.apache.hadoop.fs.Path;
import java.io.*;
public class MyFSDataInputStream extends FSDataInputStream {
    public MyFSDataInputStream(InputStream in) {
    super(in);
}
/**
    * 实现按行读取
     *每次读入一个字符,遇到"\n"结束,返回一行内容
   public static String readline (BufferedReader br) throws IOException {
        char[] data=new char[1024];
        int read=-1;
        int off=0;
        //循环执行时,br 每次会从上一次读取结束的位置继续读取
        //因此该函数里,off 每次都从 0开始
        while((read=br.read(data, off, 1)) !=-1) {
            if(String.valueOf(data[off]).equals("\n")) {
                off+=1;
               break;
            off+=1;
        if(off>0) {
           return String.valueOf (data);
        } else {
            return null;
    /**
     * 读取文件内容
     * /
   public static void cat (Configuration conf, String remoteFilePath) throws IOException {
        FileSystem fs=FileSystem.get(conf);
        Path remotePath=new Path (remoteFilePath);
        FSDataInputStream in=fs.open(remotePath);
```

```
BufferedReaderbr=new BufferedReader(new InputStreamReader(in));
        String line=null;
        while((line=MyFSDataInputStream.readline(br)) !=null) {
            System.out.println(line);
        br.close();
        in.close();
        fs.close();
    /**
     * 主函数
     * /
   public static void main(String[] args) {
        Configuration conf=new Configuration();
        conf.set("fs.default.name", "hdfs://localhost:9000");
                                                           //HDFS 路径
        String remoteFilePath="/user/hadoop/text.txt";
        try {
            MyFSDataInputStream.cat(conf, remoteFilePath);
        } catch (Exception e) {
            e.printStackTrace();
}
```

(3) 查看 Java 帮助手册或其他资料,用 java. net. URL 和 org. apache. hadoop. fs. FsURLStreamHandlerFactory 编程完成输出 HDFS 中指定文件的文本到终端中。

```
import org.apache.hadoop.fs.*;
import org.apache.hadoop.io.IOUtils;
import java.io.*;
import java.net.URL;

public class HDFSApi {
    static{
        URL.setURLStreamHandlerFactory(new FsUrlStreamHandlerFactory());
    }
    /**
    * 主函数
    * /
    public static void main(String[] args) throws Exception {
        String remoteFilePath= "hdfs:///user/hadoop/text.txt"; //HDFS 文件
        InputStream in=null;
```

```
try{
    /* 通过 URL 对象打开数据流,从中读取数据 * /
    in=new URL(remoteFilePath).openStream();
    IOUtils.copyBytes(in,System.out,4096,false);
} finally{
    IOUtils.closeStream(in);
}

}
```

# A.3 实验三: 熟悉常用的 HBase 操作

本实验对应第5章的内容。

### A.3.1 实验目的

- (1) 理解 HBase 在 Hadoop 体系结构中的角色。
- (2) 熟练使用 HBase 操作常用的 Shell 命令。
- (3) 熟悉 HBase 操作常用的 Java API。

### A.3.2 实验平台

- (1) 操作系统: Linux。
- (2) Hadoop 版本: 2.7.1 或以上版本。
- (3) HBase 版本: 1.1.2 或以上版本。
- (4) JDK 版本: 1.7 或以上版本。
- (5) Java IDE: Eclipse.

### A.3.3 实验步骤

本部分实验的完整代码 QuestionOne. java,可以到本书官网的"下载专区"的"实验答案"目录下载。

### 1. 编程实现以下指定功能,并用 Hadoop 提供的 HBase Shell 命令完成相同任务

- (1) 列出 HBase 所有的表的相关信息,例如表名。
- ① Shell 命令。

```
hbase>list
```

② Java 代码。

```
public static void listTables() throws IOException {
init(); //建立连接
```

```
HTableDescriptor hTableDescriptors[]=admin.listTables();
for(HTableDescriptor hTableDescriptor:hTableDescriptors){
    System.out.println("表名:"+hTableDescriptor.getNameAsString());
}
close(); //关闭连接
}
```

需要注意的是,上述代码需要放入到完整的程序代码中才能顺利执行。

- (2) 在终端打印出指定的表的所有记录数据。
- ① Shell 命令。

```
hbase>scan 's1'
```

② Java 代码。

```
//在终端打印出指定的表的所有记录数据
public static void getData(String tableName)throws IOException{
    init();
    Table table=connection.getTable(TableName.valueOf(tableName));
    Scan scan=new Scan();
    ResultScanner scanner=table.getScanner(scan);
    for (Result result:scanner) {
        printRecoder(result);
    close();
//打印一条记录的详情
public static void printRecoder(Result result)throws IOException{
    for(Cell cell:result.rawCells()){
        System.out.print("行键: "+ new String(CellUtil.cloneRow(cell)));
        System.out.print("列族: "+ new String(CellUtil.cloneFamily(cell)));
        System.out.print("列: "+new String(CellUtil.cloneQualifier(cell)));
        System.out.print("值: "+new String(CellUtil.cloneValue(cell)));
        System.out.println("时间戳: "+cell.getTimestamp());
}
```

- (3) 向已经创建好的表添加和删除指定的列族或列。
- ① Shell 命令。

先在 Shell 中创建表 s1,作为示例表,命令如下:

```
hbase>create 's1','score'
```

然后可以在 s1 中添加数据,命令如下:

```
hbase>put 's1','zhangsan','score:Math','69'
```

之后可以执行如下命令删除指定的列:

```
hbase>delete 's1','zhangsan','score:Math'
```

② Java 代码。

```
//向表中添加数据
public static void insertRow (String tableName, String rowKey, String colFamily, String col,
String val) throws IOException {
    init();
    Table table=connection.getTable(TableName.valueOf(tableName));
    Put put=new Put (rowKey.getBytes());
    put.addColumn(colFamily.getBytes(), col.getBytes(), val.getBytes());
    table.put(put);
    table.close();
    close();
insertRow("s1",'zhangsan','score','Math','69')
//删除数据
public static void deleteRow (String tableName, String rowKey, String colFamily, String col)
throws IOException {
    init();
    Table table=connection.getTable(TableName.valueOf(tableName));
    Delete delete=new Delete(rowKey.getBytes());
    //删除指定列族
    delete.addFamily(Bytes.toBytes(colFamily));
    //删除指定列
    delete.addColumn(Bytes.toBytes(colFamily),Bytes.toBytes(col));
    table.delete(delete);
    table.close();
    close();
deleteRow("s1", 'zhangsan', 'score', 'Math')
```

- (4) 清空指定的表的所有记录数据。
- ① Shell 命令。

```
hbase>truncate 's1'
```

② Java 代码。

```
//清空指定的表的所有记录数据
public static void clearRows(String tableName)throws IOException{
    init();
    TableName tablename= TableName.valueOf(tableName);
    admin.disableTable(tablename);
    admin.deleteTable(tablename);
    HTableDescriptor hTableDescriptor= new HTableDescriptor(tableName);
    admin.createTable(hTableDescriptor);
    close();
}
```

- (5) 统计表的行数。
- ① Shell 命令。

```
hbase>count 's1'
```

② Java 代码。

```
//(5)统计表的行数
public static void countRows(String tableName)throws IOException{
init();
    Table table=connection.getTable(TableName.valueOf(tableName));
    Scan scan=new Scan();
    ResultScanner scanner=table.getScanner(scan);
    int num=0;
    for(Result result=scanner.next();result!=null;result=scanner.next()){
        num++;
    }
    System.out.println("行数:"+num);
    scanner.close();
    close();
}
```

#### 2. HBase 数据库操作

(1) 现有以下关系型数据库中的表和数据(见表 A-1~表 A-3),要求将其转换为适合于 HBase 存储的表并插入数据。

学号(S_No)	姓名(S_Name)	性别(S_Sex)	年龄(S_Age)
2015001	Zhangsan	male	23
2015003	Mary	female	22
2015003	Lisi	male	24

表 A-1 学生表(Student)

表 A-2 课程表(Course)

课程号(C_No)	课程名(C_Name)	学分(C_Credit)
123001	Math	2.0
123002	Computer Science	5.0
123003	English	3.0

#### 表 A-3 选课表(SC)

学号(SC_Sno)	课程号(SC_Cno)	成绩(SC_Score)
2015001	123001	86
2015001	123003	69
2015002	123002	77
2015002	123003	99
2015003	123001	98
2015003	123002	95

① 学生 Student 表。

创建表的 HBase Shell 命令语句如下:

hbase>create 'Student', 'S\_No', 'S\_Name', 'S\_Sex', 'S\_Age'

# 插入数据的 HBase Shell 命令如下:

	插入数据的 HBase Shell 命令		
	put 'Student','s001','S_No','2015001'		
第一行数据	put 'Student','s001','S_Name','Zhangsan'		
77 17 致16	put 'Student','s001','S_Sex','male'		
	put 'Student','s001','S_Age','23'		
	put 'Student','s002','S_No','2015002'		
第二行数据	put 'Student','s002','S_Name','Mary'		
	put 'Student','s002','S_Sex','female'		
	put 'Student','s002','S_Age','22'		
	put 'Student','s003','S_No','2015003'		
第三行数据	put 'Student','s003','S_Name','Lisi'		
和二11数值	put 'Student','s003','S_Sex','male'		
	put 'Student','s003','S_Age','24'		

② 课程 Course 表。

创建表的 HBase Shell 命令语句如下:

hbase>create 'Course', 'C\_No', 'C\_Name', 'C\_Credit'

# 插入数据的 HBase Shell 命令如下:

	插入数据的 HBase Shell 命令	
第一行数据	<pre>put'Course','c001','C_No','123001' put 'Course','c001','C_Name','Math' put 'Course','c001','C_Credit','2.0'</pre>	
第二行数据	<pre>put 'Course','c002','C_No','123002' put 'Course','c002','C_Name','Computer' put 'Course','c002','C_Credit','5.0'</pre>	
第三行数据	<pre>put 'Course','c003','C_No','123003' put 'Course','c003','C_Name','English' put 'Course','c003','C_Credit','3.0'</pre>	

# ③ 选课表。

创建表的 HBase Shell 命令语句如下:

```
hbase>create 'SC', 'SC_Sno', 'SC_Cno', 'SC_Score'
```

# 插入数据的 HBase Shell 命令如下:

	插入数据的 HBase Shell 命令	
第一行数据	<pre>put 'SC', 'sc001', 'SC_Sno', '2015001' put 'SC', 'sc001', 'SC_Cno', '123001' put 'SC', 'sc001', 'SC_Score', '86'</pre>	
第二行数据	<pre>put 'SC', 'sc002', 'SC_Sno', '2015001' put 'SC', 'sc002', 'SC_Cno', '123003' put 'SC', 'sc002', 'SC_Score', '69'</pre>	
第三行数据	<pre>put 'SC', 'sc003', 'SC_Sno', '2015002' put 'SC', 'sc003', 'SC_Cno', '123002' put 'SC', 'sc003', 'SC_Score', '77'</pre>	
第四行数据	<pre>put 'SC', 'sc004', 'SC_Sno', '2015002' put 'SC', 'sc004', 'SC_Cno', '123003' put 'SC', 'sc004', 'SC_Score', '99'</pre>	
第五行数据	<pre>put 'SC', 'sc005', 'SC_Sno', '2015003' put 'SC', 'sc005', 'SC_Cno', '123001' put 'SC', 'sc005', 'SC_Score', '98'</pre>	
第六行数据	<pre>put 'SC', 'sc006', 'SC_Sno', '2015003' put 'SC', 'sc006', 'SC_Cno', '123002' put 'SC', 'sc006', 'SC_Score', '95'</pre>	

- (2) 请编程实现以下功能。
- ① createTable(String tableName, String[] fields)。

创建表,参数 tableName 为表的名称,字符串数组 fields 为存储记录各个字段名称的数组。要求当 HBase 已经存在名为 tableName 的表时,先删除原有的表,然后再创建新的表。与本小题对应的参考代码如下:

```
public static void createTable(String tableName, String[] fields) throws IOException {
    init();
    TableName tablename=TableName.valueOf(tableName);
    if(admin.tableExists(tablename)){
        System.out.println("tableis exists!");
        admin.disableTable(tablename);
        admin.deleteTable(tablename);//删除原来的表
    }
    HTableDescriptor hTableDescriptor=new HTableDescriptor(tablename);
    for(String str:fields) {
        HColumnDescriptor hColumnDescriptor=newHColumnDescriptor(str);
        hTableDescriptor.addFamily(hColumnDescriptor);
    }
    admin.createTable(hTableDescriptor);
    close();
}
```

上述代码需要放入完整的程序代码中才可以顺利执行,可以到本书官网的"下载专区"的"实验答案"目录下载完整的程序代码 QuestionTwo.java。

② addRecord(String tableName, String row, String[] fields, String[] values)。

向表 tableName、行 row(用 S\_Name 表示)和字符串数组 fields 指定的单元格中添加对应的数据 values。其中, fields 中每个元素如果对应的列族下还有相应的列限定符,用columnFamily:column表示。例如,同时向 Math、Computer Science、English 三列添加成绩时,字符串数组 fields 为{"Score: Math","Score: Computer Science","Score: English"},数组 values 存储这三门课的成绩。

本题的参考代码如下:

```
public static void addRecord(String tableName,String row,String[] fields,String[] values)
throws IOException {
   init();
   Table table=connection.getTable(TableName.valueOf(tableName));
   for(int i=0;i != fields.length;i++) {
      Put put=new Put(row.getBytes());
      String[] cols=fields[i].split(":");
      put.addColumn(cols[0].getBytes(), cols[1].getBytes(), values[i].
      getBytes());
```

```
table.put(put);
}
table.close();
close();
}
```

上述代码需要放入完整的程序代码中才可以顺利执行。

③ scanColumn(String tableName, String column)。

浏览表 tableName 某一列的数据,如果某一行记录中该列数据不存在,则返回 null。要求当参数 column 为某一列族名称时,如果底下有若干个列限定符,则要列出每个列限定符代表的列的数据;当参数 column 为某一列具体名称(例如"Score: Math")时,只需要列出该列的数据。

```
public static void scanColumn (String tableName, String column) throws IOException {
    init();
    Table table=connection.getTable(TableName.valueOf(tableName));
    Scan scan=new Scan();
    scan.addFamily(Bytes.toBytes(column));
    ResultScanner scanner=table.getScanner(scan);
    for (Result result=scanner.next(); result !=null; result=scanner.next()) {
        showCell(result);
    table.close();
    close();
//格式化输出
public static void showCell (Result result) {
    Cell[] cells=result.rawCells();
    for (Cell cell:cells) {
        System.out.println("RowName:"+ new String(CellUtil.cloneRow(cell))+"");
        System.out.println("Timetamp:"+cell.getTimestamp()+"");
        System.out.println("column Family:"+ new String(CellUtil.cloneFamily(cell))+"");
        System.out.println("row Name:"+new String(CellUtil.cloneQualifier(cell))+"");
        System.out.println("value:"+new String(CellUtil.cloneValue(cell))+"");
}
```

@ modifyData(String tableName, String row, String column).

修改表 tableName,即修改行 row(可以用学生姓名 S\_Name 表示)、列 column 指定的单元格的数据。

```
public static void modifyData(String tableName, String row, String column, String val) throws
IOException{
    init();
    Table table=connection.getTable(TableName.valueOf(tableName));
    Put put=new Put(row.getBytes());
    put.addColumn(column.getBytes(), null, val.getBytes());
    table.put(put);
    table.close();
    close();
}
```

⑤ deleteRow(String tableName, String row)。 删除表 tableName 中 row 指定的行的记录。

```
public static void deleteRow(String tableName,String row)throws IOException{
    init();
    Table table=connection.getTable(TableName.valueOf(tableName));
    Delete delete=new Delete(row.getBytes());
    //删除指定列族
    //delete.addFamily(Bytes.toBytes(colFamily));
    //删除指定列
    //delete.addColumn(Bytes.toBytes(colFamily),Bytes.toBytes(col));
    table.delete(delete);
    table.close();
    close();
}
```

# A. 4 实验四: NoSQL 和关系数据库的操作比较

本实验对应第6章的内容。

# A.4.1 实验目的

- (1) 理解 4 种数据库(MySQL、HBase、Redis 和 MongoDB)的概念及不同点。
- (2) 熟练使用 4 种数据库操作常用的 Shell 命令。
- (3) 熟悉 4 种数据库操作常用的 Java API。

### A.4.2 实验平台

- (1) 操作系统: Linux(建议 Ubuntu 16.04)。
- (2) Hadoop 版本: 2.7.1。
- (3) MySQL 版本: 5.7.15。
- (4) HBase 版本: 1.1.2。
- (5) Redis 版本: 3.0.6。

- (6) MongoDB 版本: 3.2.6。
- (7) JDK 版本: 1.7 或以上版本。
- (8) Java IDE: Eclipse.

### A.4.3 实验步骤

# 1. MySQL 数据库操作

Student 表如表 A-4 所示。

表 A-4 Student 表

Name	English	Math	Computer
zhangsan	69	86	77
lisi	55	100	88

- (1) 根据上面给出的 Student 表,在 MySQL 数据库中完成如下操作。
- ① 在 MySQL 中创建 Student 表,并录入数据。

创建 Student 表的 SQL 语句如下:

```
create table student(
name varchar(30) not null,
English tinyint unsigned not null,
Math tinyint unsigned not null,
Computer tinyint unsigned not null
);
```

向 Student 表中插入两条记录的 SQL 语句如下:

```
insert into student values("zhangsan",69,86,77);
insert into student values("lisi",55,100,88);
```

② 用 SQL 语句输出 Student 表中的所有记录。 输出 Student 表中的所有记录的 SQL 语句如下:

```
select * from student;
```

上述 SQL 语句执行后的结果截图如图 A-1 所示。

图 A-1 结果截图(1)

③ 查询 zhangsan 的 Computer 成绩。 查询 zhangsan 的 Computer 成绩的 SQL 语句如下:

```
select name , Computer from student where name="zhangsan";
```

上述语句执行后的结果截图如图 A-2 所示。

图 A-2 结果截图(2)

④ 修改 lisi 的 Math 成绩,改为 95。 修改 lisi 的 Math 成绩的 SQL 语句如下:

```
update student set Math=95 where name="lisi";
```

上述 SQL 语句执行结果截图如图 A-3 所示。

```
mysql> update student set Math=95 where name="lisi";
Query OK, 0 rows affected (0.05 sec)
Rows matched: 1 Changed: 0 Warnings: 0

mysql> select name, Math from student where name = "lisi";
+----+
| name | Math |
+----+
| lisi | 95 |
+----+
1 row in set (0.00 sec)
```

图 A-3 结果截图(3)

- (2) 根据上面已经设计出的 Student 表,使用 MySQL 的 Java 客户端编程实现以下操作。
  - ① 向 Student 表中添加如下所示的一条记录:

```
scofield 45 89 100
```

向 Student 表添加上述记录的 Java 代码如下:

```
import java.sql.*;
public class mysql_test {

   /**
    * @ param args
    * /
    //JDBC DRIVER and DB
    static final String DRIVER="com.mysql.jdbc.Driver";
```

```
static final String DB="jdbc:mysql://localhost/test";
//Database auth
static final String USER= "root";
static final String PASSWD="root";
public static void main(String[] args) {
    //TODO Auto-generated method stub
    Connection conn=null;
    Statement stmt=null;
    try {
        //加载驱动程序
        Class.forName(DRIVER);
        System.out.println("Connecting to a selected database"");
        //打开一个连接
        conn=DriverManager.getConnection(DB, USER, PASSWD);
        //执行一个查询
        stmt=conn.createStatement();
        String sql="insert into student values('scofield', 45, 89, 100)";
        stmt.executeUpdate(sql);
        System.out.println("Inserting records into the table successfully!");
    } catch (ClassNotFoundException e) {
        //TODO Auto-generated catch block
        e.printStackTrace();
    }catch (SQLException e) {
        //TODO Auto-generated catch block
        e.printStackTrace();
    }finally
        if (stmt!=null)
            try {
                 stmt.close();
            } catch (SQLException e) {
                 //TODO Auto-generated catch block
                 e.printStackTrace();
            }
        if(conn!=null)
            try {
                 conn.close();
            } catch (SQLException e) {
                 //TODO Auto-generated catch block
                 e.printStackTrace();
```

② 获取 scofield 的 English 成绩信息。 获取 scofield 的 English 成绩信息的 Java 代码如下:

```
import java.sql. *;
public class mysql qurty {
/**
     * @param args
    //JDBC DRIVER and DB
    static final String DRIVER= "com.mysql.jdbc.Driver";
    static final String DB="jdbc:mysql://localhost/test";
    //Database auth
    static final String USER= "root";
    static final String PASSWD="root";
    public static void main(String[] args) {
        //TODO Auto-generated method stub
        Connection conn=null;
        Statement stmt=null;
        ResultSet rs=null;
        try {
            //加载驱动程序
            Class.forName (DRIVER);
            System.out.println("Connecting to a selected database"");
            //打开一个连接
            conn=DriverManager.getConnection(DB, USER, PASSWD);
            //执行一个查询
            stmt=conn.createStatement();
            String sql="select name, English from student where name= 'scofield' ";
            //获得结果集
            rs=stmt.executeQuery(sql);
            System.out.println("name"+"\t\t"+"English");
            while(rs.next())
                System.out.print(rs.getString(1)+"\t\t");
                System.out.println(rs.getInt(2));
            }
        } catch (ClassNotFoundException e) {
            //TODO Auto-generated catch block
            e.printStackTrace();
        }catch (SQLException e) {
            //TODO Auto-generated catch block
            e.printStackTrace();
```

```
}finally
    if(rs!=null)
        try {
            rs.close();
        } catch (SQLException e1) {
            //TODO Auto-generated catch block
            el.printStackTrace();
        }
    if(stmt!=null)
        try {
            stmt.close();
        } catch (SQLException e) {
            //TODO Auto-generated catch block
            e.printStackTrace();
if(conn!=null)
        try {
            conn.close();
        } catch (SQLException e) {
            //TODO Auto-generated catch block
            e.printStackTrace();
```

### 2. HBase 数据库操作

Student 表如表 A-5 所示。

表 A-5 Student 表

	score		
name	English	Math	Computer
zhangsan	69	86	77
lisi	55	100	88

- (1) 根据上面给出的 Student 表的信息,执行如下操作。
- ① 用 HBase Shell 命令创建学生表 Student。

创建 Student 表的命令如下:

```
create 'student', 'score'
```

向 Student 表中插入上面表格数据的命令如下:

```
put 'student', 'zhangsan', 'score:English', '69'
put 'student', 'zhangsan', 'score:Math', '86'
put 'student', 'zhangsan', 'score:Computer', '77'
put 'student', 'lisi', 'score:English', '55'
put 'student', 'lisi', 'score:Math', '100'
put 'student', 'lisi', 'score:Computer', '88'
```

上述命令执行结果截图如图 A-4 所示。

```
hbase(main):018:0> create 'student','score'
0 row(s) in 2.2800 seconds

=> Hbase::Table - student
hbase(main):019:0> put 'student','zhangsan','score:English','69'
0 row(s) in 0.0240 seconds

hbase(main):020:0> put 'student','zhangsan','score:Math','86'
0 row(s) in 0.0070 seconds

hbase(main):021:0> put 'student','zhangsan','score:Computer','77'
0 row(s) in 0.0060 seconds

hbase(main):022:0> put 'student','lisi','score:English','55'
0 row(s) in 0.0100 seconds

hbase(main):023:0> put 'student','lisi','score:Math','100'
0 row(s) in 0.0080 seconds

hbase(main):024:0> put 'student','lisi','score:Computer','88'
0 row(s) in 0.0080 seconds
```

图 A-4 结果截图(4)

② 用 scan 指令浏览 Student 表的相关信息。 用 scan 指令浏览 Student 表相关信息的命令如下:

```
scan 'student'
```

上述命令执行结果截图如图 A-5 所示。

```
hbase(main):001:0> scan 'student'

ROW COLUMN+CELL

lisi column=score:Computer, timestamp=1462605149677, value=88

lisi column=score:English, timestamp=1462605127827, value=55

lisi column=score:Math, timestamp=1462605138004, value=100

zhangsan column=score:Computer, timestamp=1462605105787, value=77

zhangsan column=score:English, timestamp=1462605086516, value=69

zhangsan column=score:Math, timestamp=1462605096683, value=86

2 row(s) in 0.3410 seconds
```

图 A-5 结果截图(5)

③ 查询 zhangsan 的 Computer 成绩。 查询 zhangsan 的 Computer 成绩的命令如下:

```
get 'student', 'zhangsan', 'score:Computer'
```

上述命令执行结果截图如图 A-6 所示。

```
hbase(main):002:0> get 'student','zhangsan','score:Computer'
COLUMN CELL
score:Computer timestamp=1462605105787, value=77
1 row(s) in 0.0610 seconds
```

图 A-6 结果截图(6)

④ 修改 lisi 的 Math 成绩,改为 95。 修改 lisi 的 Math 成绩的命令如下:

```
put 'student','lisi','score:Math','95'
```

上述命令的执行结果截图如图 A-7 所示。

```
hbase(main):003:0> put 'student','lisi','score:Math','95'
0 row(s) in 0.1020 seconds
hbase(main):004:0> get 'student','lisi','score:Math'
COLUMN CELL
score:Math timestamp=1462605841339, value=95
1 row(s) in 0.0090 seconds
```

图 A-7 结果截图(7)

- (2) 根据上面已经设计出的 Student 表,用 HBase API 编程实现以下操作。
- ① 添加数据: English 为 45; Math 为 89; Computer 为 100。

#### 实现添加数据的 Java 代码如下:

```
import java.io.IOException;
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.hbase.HBaseConfiguration;
import org.apache.hadoop.hbase.TableName;
import org.apache.hadoop.hbase.client.Admin;
import org.apache.hadoop.hbase.client.Connection;
import org.apache.hadoop.hbase.client.ConnectionFactory;
import org.apache.hadoop.hbase.client.Put;
import org.apache.hadoop.hbase.client.Table;

public class hbase_insert {

    /**

    * @ param args

    * /
    public static Configuration configuration;
```

```
public static Connection connection;
        public static Admin admin;
        public static void main (String[] args) {
        //TODO Auto-generated method stub
        configuration=HBaseConfiguration.create();
        configuration.set("hbase.rootdir", "hdfs://localhost:9000/hbase");
        try{
             connection=ConnectionFactory.createConnection(configuration);
             admin=connection.getAdmin();
        }catch (IOException e) {
            e.printStackTrace();
        }
        try {
             insertRow("student", "scofield", "score", "English", "45");
             insertRow("student", "scofield", "score", "Math", "89");
             insertRow("student", "scofield", "score", "Computer", "100");
        } catch (IOException e) {
             //TODO Auto-generated catch block
            e.printStackTrace();
        close();
    public static void insertRow (String tableName, String rowKey, String
    colFamily, String col, String val) throws IOException {
        Table table=connection.getTable(TableName.valueOf(tableName));
        Put put=new Put (rowKey.getBytes());
        put.addColumn(colFamily.getBytes(), col.getBytes(), val.getBytes());
        table.put(put);
        table.close();
    public static void close(){
            try{
                 if(admin !=null){
                     admin.close();
                 if(null != connection) {
                     connection.close();
             }catch (IOException e) {
                 e.printStackTrace();
             }
}
```

执行完上述代码以后,可以用 scan 命令输出数据库数据,以检验是否插入成功,执行结果截图如图 A-8 所示。

```
hbase(main):005:0> scan 'student'
ROW
lisi
                            column=score:Computer, timestamp=1462605149677, value=88
lisi
                            column=score:English, timestamp=1462605127827, value=55
 lisi
                            column=score:Math, timestamp=1462605841339, value=95
 scofield
                            column=score:Computer, timestamp=1462607153886, value=100
 scofield
                            column=score:English, timestamp=1462607153858, value=45
 scofield
                            column=score:Math, timestamp=1462607153883, value=89
 zhangsan
                            column=score:Computer, timestamp=1462605105787, value=77
 zhangsan
                            column=score:English, timestamp=1462605086516, value=69
 zhangsan
                            column=score:Math, timestamp=1462605096683, value=86
 row(s) in 0.0390 seconds
```

图 A-8 结果截图(8)

② 获取 scofield 的 English 成绩信息。 Java 代码如下:

```
import java.io.IOException;
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.hbase.Cell;
import org.apache.hadoop.hbase.CellUtil;
import org.apache.hadoop.hbase.HBaseConfiguration;
import org.apache.hadoop.hbase.TableName;
import org.apache.hadoop.hbase.client.Admin;
import org.apache.hadoop.hbase.client.Connection;
import org.apache.hadoop.hbase.client.ConnectionFactory;
import org.apache.hadoop.hbase.client.Get;
import org.apache.hadoop.hbase.client.Put;
import org.apache.hadoop.hbase.client.Result;
import org.apache.hadoop.hbase.client.Table;
public class hbase_query {
    /**
     * @param args
    public static Configuration configuration;
    public static Connection connection;
    public static Admin admin;
    public static void main(String[] args) {
        //TODO Auto-generated method stub
        configuration=HBaseConfiguration.create();
        configuration.set("hbase.rootdir", "hdfs://localhost:9000/hbase");
        try{
             connection=ConnectionFactory.createConnection(configuration);
             admin=connection.getAdmin();
        }catch (IOException e) {
```

```
e.printStackTrace();
        }
        try {
            getData("student", "scofield", "score", "English");
        } catch (IOException e) {
            //TODO Auto-generated catch block
            e.printStackTrace();
        close();
    public static void getData (String tableName, String rowKey, String
    colFamily,String col)throws IOException{
          Table table=connection.getTable(TableName.valueOf(tableName));
          Get get=new Get(rowKey.getBytes());
          get.addColumn(colFamily.getBytes(),col.getBytes());
          Result result=table.get(get);
          showCell(result);
          table.close();
    public static void showCell (Result result) {
          Cell[] cells=result.rawCells();
          for(Cell cell:cells){
              System.out.println("RowName:"+new String(CellUtil.cloneRow(
               cell))+"");
              System.out.println("Timetamp:"+cell.getTimestamp()+"");
              System.out.println("column Family:"+new String(CellUtil.
              cloneFamily(cell))+"");
               System.out.println("row Name:"+new String(CellUtil.
               cloneQualifier(cell))+"");
               System.out.println("value:"+ new String(CellUtil.cloneValue
               (cell))+"");
    public static void close(){
            try{
                 if(admin !=null){
                     admin.close();
                 }
                if(null !=connection) {
                     connection.close();
                 }
            }catch (IOException e) {
                e.printStackTrace();
            }
}
```

可以在 Eclipse 中执行上述代码,会在控制台中输出如下信息:

RowName:scofield Timetamp:1462607153858 column Family:score row Name:English value:45

#### 3. Redis 数据库操作

Student 键值对如下:

```
zhangsan:{
          English: 69
          Math: 86
          Computer: 77
}
lisi:{
          English: 55
          Math: 100
          Computer: 88
}
```

- (1) 根据上面给出的键值对,完成如下操作。
- ① 用 Redis 的哈希结构设计出学生表 Student (键值可以用 student. zhangsan 和 student. lisi 来表示两个键值属于同一个表)。

插入上述键值对的命令如下:

```
hset student.zhangsan English 69
hset student.zhangsan Math 86
hset student.zhangsan Computer 77
hset student.lisi English 55
hset student.lisi Math 100
hset student.lisi Computer 88
```

② 用 hgetall 命令分别输出 zhangsan 和 lisi 的成绩信息。 查询 zhangsan 成绩信息的命令如下:

```
hgetall student.zhangsan
```

执行该命令的结果截图如图 A-9 所示。

```
127.0.0.1:6379> hgetall student.zhangsan

1) "English"

2) "69"

3) "Math"

4) "86"

5) "Computer"

6) "77"
```

图 A-9 结果截图(9)

查询 lisi 成绩信息的命令如下:

```
hgetall student.lisi
```

执行该命令的结果截图如图 A-10 所示。

```
127.0.0.1:6379> hgetall student.lisi
1) "English"
2) "55"
3) "Math"
4) "100"
5) "Computer"
6) "88"
```

图 A-10 结果截图(10)

③ 用 hget 命令查询 zhangsan 的 Computer 成绩。 查询 zhangsan 的 Computer 成绩的命令如下:

```
hget student.zhangsan Computer
```

执行该命令的结果截图如图 A-11 所示。

```
127.0.0.1:6379> hget student.zhangsan Computer "77"
```

图 A-11 结果截图(11)

④ 修改 lisi 的 Math 成绩,改为 95。 修改 lisi 的 Math 成绩的命令如下:

```
hset student.lisi Math 95
```

执行该命令的结果截图如图 A-12 所示。

```
127.0.0.1:6379> hset student.lisi Math 95 (integer) 0
```

图 A-12 结果截图(12)

- (2) 根据上面已经设计出的学生表 Student,用 Redis 的 Java 客户端编程(jedis),实现如下操作。
  - ① 添加数据: English 为 45; Math 为 89; Computer 为 100。

```
scofield: {
     English: 45
     Math: 89
     Computer: 100
}
```

完成添加数据操作的 Java 代码如下:

```
import java.util.Map;
import redis.clients.jedis.Jedis;
public class jedis_test {
    /**
     * @param args
     * /
    public static void main(String[] args) {
        //TODO Auto-generated method stub
        Jedis jedis=new Jedis("localhost");
        jedis.hset("student.scofield", "English", "45");
        jedis.hset("student.scofield", "Math", "89");
        jedis.hset("student.scofield", "Computer", "100");
        Map<String,String>value=jedis.hgetAll("student.scofield");
        for (Map.Entry<String, String>entry:value.entrySet())
            System.out.println(entry.getKey()+":"+entry.getValue());
}
```

在 Eclipse 中执行上述代码后,在 Eclipse 控制台输出的信息 截图如图 A-13 所示。

② 获取 scofield 的 English 成绩信息。 获取 scofield 的 English 成绩信息的 Java 代码如下: Computer:100 Math:89 English:45

图 A-13 信息截图(1)

```
import java.util.Map;
import redis.clients.jedis.Jedis;

public class jedis_query {

    /**
    * @ param args
    * /
    public static void main(String[] args) {
        //TODO Auto- generated method stub
        Jedis jedis= new Jedis("localhost");
        String value= jedis.hget("student.scofield", "English");
        System.out.println("scofield's English score is: "+value);
    }
}
```

在 Eclipse 中执行上述代码后,在 Eclipse 控制台输出的信息截图如图 A-14 所示。

```
scofield's English score is: 45
```

图 A-14 信息截图(2)

### 4. MongoDB数据库操作

Student 文档如下:

```
{
    "name": "zhangsan",
    "score": {
        "English": 69,
        "Math": 86,
        "Computer": 77
    }
}

{
    "name": "lisi",
    "score": {
        "English": 55,
        "Math": 100,
        "Computer": 88
    }
}
```

- (1) 根据上面给出的文档,完成如下操作。
- ① 用 MongoDB Shell 设计出 student 集合。 首先切换到 student 集合,命令如下:

```
use student
```

然后定义包含上述两个文档的数组,命令如下:

```
var stus=[
{"name":"zhangsan","scores":{"English":69,"Math":86,"Computer":77}},
{"name":"lisi","score":{"English":55,"Math":100,"Computer":88}}]
```

最后调用如下命令插入数据库:

```
db.student.insert(stus)
```

上述命令及其执行结果的截图如图 A-15 所示。

图 A-15 结果截图(13)

② 用 find()方法输出两个学生的信息。 用 find()方法输出两个学生信息的命令如下:

```
db.student.find().pretty()
```

上述命令及其执行结果的截图如图 A-16 所示。

图 A-16 结果截图(14)

③ 用 find 函数查询 zhangsan 的所有成绩(只显示 score 列)。 用 find 函数查询 zhangsan 的所有成绩的命令如下:

```
db.student.find({"name":"zhangsan"},{"_id":0,"name":0})
```

上述命令及其执行结果的截图如图 A-17 所示。

```
b.student.find({"name":"zhangsan"},{"_id":0,"name":0})
{ "scores" : { "English" : 69, "Math" : 86, "Computer" : 77 } }
```

图 A-17 结果截图(15)

④ 修改 lisi 的 Math 成绩,改为 95。

修改 lisi 的 Math 成绩的命令如下:

```
db.student.update({"name":"lisi"}, {"$set":{"score.Math":95}})
```

上述命令及其执行结果的截图如图 A-18 所示。

图 A-18 结果截图(16)

- (2) 根据上面已经设计出的 Student 集合,用 MongoDB 的 Java 客户端编程,实现如下操作。
  - ① 添加数据: English 为 45; Math 为 89; Computer 为 100。

与上述数据对应的文档形式如下:

```
"name":"scofield",
    "score": {
         "English": 45,
         "Math": 89,
         "Computer": 100
     }
}
```

实现上述添加数据操作的 Java 代码如下:

```
import java.util.ArrayList;
import java.util.List;

import org.bson.Document;
import com.mongodb.MongoClient;
import com.mongodb.client.MongoCollection;
import com.mongodb.client.MongoDatabase;

public class mongo_insert {

/**

* @ param args

* /

public static void main(String[] args) {

//TODO Auto- generated method stub

//实例化一个 mongo 客户端

MongoClient mongoClient= new MongoClient("localhost",27017);
```

```
//实例化一个 mongo 数据库
MongoDatabase mongoDatabase=mongoClient.getDatabase("student");
//获取数据库中的某个集合
MongoCollection
MongoCollection
("student");
//实例化一个文档,内嵌一个子文档
Document document=new Document("name","scofield").

append("score", new Document("English",45).

append("Math", 89).

append("Computer", 100));
List<Document>documents=new ArrayList<Document>();
documents.add(document);
//将文档插入集合中
collection.insertMany(documents);
System.out.println("文档插入成功");
}
```

可以使用 find()方法验证数据是否已经成功插入到 MongoDB 数据库中,具体命令及其执行结果截图如图 A-19 所示。

```
db.student.find().pretty()
      "_id" : ObjectId("572daa49ac079cb68a23068e"),
      "name" : "zhangsan",
      "scores" : {
              "English" : 69,
              "Math" : 86,
              "Computer" : 77
      "_id" : ObjectId("572daa49ac079cb68a23068f"),
      "name" : "lisi",
              "English" : 55,
              "Math" : 95,
              "Computer" : 88
      "_id" : ObjectId("572db5296381924c1aacc9e4"),
      "name" : "scofield",
      "score" : {
              "English" : 45,
              "Math" : 89,
              "Computer" : 100
```

图 A-19 结果截图(17)

② 获取 scofield 的所有成绩成绩信息(只显示 score 列)。 Java 代码如下:

```
import java.util.ArrayList;
import java.util.List;
```

```
import org.bson.Document;
import com.mongodb.MongoClient;
import com.mongodb.client.MongoCollection;
import com.mongodb.client.MongoCursor;
import com.mongodb.client.MongoDatabase;
import com.mongodb.client.model.Filters;
import static com.mongodb.client.model.Filters.eq;
public class mongo query {
    /**
     * @param args
    public static void main(String[] args) {
        //TODO Auto-generated method stub
        //实例化一个 mongo 客户端
        MongoClient mongoClient=new MongoClient ("localhost", 27017);
        //实例化一个 mongo 数据库
        MongoDatabase mongoDatabase=mongoClient.getDatabase("student");
        //获取数据库中的某个集合
        MongoCollection < Document > collection = mongoDatabase.getCollection
        ("student");
        //进行数据查找,查询条件为 name=scofield, 对获取的结果集只显示 score 这个域
        MongoCursor < Document > cursor = collection.find (new Document ("name",
        "scofield")).
            projection(new Document("score",1).append("_id", 0)).iterator();
        while(cursor.hasNext())
            System.out.println(cursor.next().toJson());
```

# A. 5 实验五: MapReduce 初级编程实践

本实验对应第7章的内容。

#### A.5.1 实验目的

- (1) 通过实验掌握基本的 MapReduce 编程方法。
- (2) 掌握用 MapReduce 解决一些常见的数据处理问题,包括数据去重、数据排序和数据挖掘等。

#### A. 5. 2 实验平台

- (1) 操作系统: Linux(建议 Ubuntu 16.04)。
- (2) Hadoop 版本: 2.7.1。

### A.5.3 实验步骤

#### 1. 编程实现文件合并和去重操作

对于两个输入文件,即文件 A 和文件 B,编写 MapReduce 程序,对两个文件进行合并,并剔除其中重复的内容,得到一个新的输出文件 C。下面是输入文件和输出文件的一个样例供参考。

输入文件 A 的样例如下:

```
20170101 x

20170102 y

20170103 x

20170104 y

20170105 z

20170106 x
```

#### 输入文件 B 的样例如下:

```
20170101 y
20170102 y
20170103 x
20170104 z
20170105 y
```

根据输入文件 A 和 B 合并得到的输出文件 C 的样例如下:

```
20170101 x
20170101 y
20170102 y
20170103 x
20170104 y
20170105 y
20170105 z
20170106 x
```

#### 实现上述操作的 Java 代码如下:

```
package com.Merge;
import java.io.IOException;
import org.apache.hadoop.conf.Configuration;
```

```
import org.apache.hadoop.fs.Path;
import org.apache.hadoop.io.IntWritable;
import org.apache.hadoop.io.Text;
import org.apache.hadoop.mapreduce.Job;
import org.apache.hadoop.mapreduce.Mapper;
import org.apache.hadoop.mapreduce.Reducer;
import org.apache.hadoop.mapreduce.lib.input.FileInputFormat;
import org.apache.hadoop.mapreduce.lib.output.FileOutputFormat;
import org.apache.hadoop.util.GenericOptionsParser;
public class Merge {
    /**
     * @param args
     * 对 A、B 两个文件进行合并,并剔除其中重复的内容,得到一个新的输出文件 C
     * /
    //重载 map 函数,直接将输入中的 value 复制到输出数据的 key上
    public static class Map extends Mapper<Object, Text, Text, Text> {
        private static Text text=new Text();
        public void map (Object key, Text value, Context context) throws
        IOException, InterruptedException{
            text=value;
            context.write(text, new Text(""));
    //重载 reduce 函数,直接将输入中的 key 复制到输出数据的 key 上
    public static class Reduce extends Reducer<Text, Text, Text> {
        public void reduce(Text key, Iterable<Text>values, Context context)
        throws IOException, InterruptedException {
            context.write(key, new Text(""));
    public static void main(String[] args) throws Exception{
        //TODO Auto-generated method stub
        Configuration conf=new Configuration();
        conf.set("fs.default.name", "hdfs://localhost:9000");
        String[] otherArgs=new String[]{"input","output"}; /* 直接设置输入参数 */
        if(otherArgs.length != 2) {
            System.err.println("Usage: wordcount<in><out>");
            System.exit(2);
```

```
Job job=Job.getInstance(conf, "Merge and duplicate removal");
    job.setJarByClass(Merge.class);
    job.setMapperClass(Map.class);
    job.setCombinerClass(Reduce.class);
    job.setReducerClass(Reduce.class);
    job.setOutputKeyClass(Text.class);
    job.setOutputValueClass(Text.class);
    FileInputFormat.addInputPath(job, new Path(otherArgs[0]));
    FileOutputFormat.setOutputPath(job, new Path(otherArgs[1]));
    System.exit(job.waitForCompletion(true) ? 0 : 1);
}
```

#### 2. 编写程序实现对输入文件的排序

现在有多个输入文件,每个文件中的每行内容均为一个整数。要求读取所有文件中的整数,进行升序排序后,输出到一个新的文件中,输出的数据格式为每行两个整数,第一个数字为第二个整数的排序位次,第二个整数为原待排列的整数。下面是输入文件和输出文件的一个样例供参考。

输入文件1的样例如下:

```
33
37
12
40
```

输入文件 2 的样例如下:

```
4
16
39
5
```

输入文件 3 的样例如下:

```
1
45
25
```

根据输入文件 1、2 和 3 得到的输出文件如下:

```
1 1
2 4
3 5
4 12
5 16
6 25
7 33
8 37
9 39
10 40
11 45
```

#### 实现上述操作的 Java 代码如下:

```
package com.MergeSort;
import java.io.IOException;
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.Path;
import org.apache.hadoop.io.IntWritable;
import org.apache.hadoop.io.Text;
import org.apache.hadoop.mapreduce.Job;
import org.apache.hadoop.mapreduce.Mapper;
import org.apache.hadoop.mapreduce.Partitioner;
import org.apache.hadoop.mapreduce.Reducer;
import org.apache.hadoop.mapreduce.lib.input.FileInputFormat;
import org.apache.hadoop.mapreduce.lib.output.FileOutputFormat;
import org.apache.hadoop.util.GenericOptionsParser;
public class MergeSort {
    /**
     * @param args
    * 输入多个文件,每个文件中的每行内容均为一个整数
    * 输出到一个新的文件中,输出的数据格式为每行两个整数,第一个数字为第二个整数的排
       序位次,第二个整数为原待排列的整数
     * /
   //map 函数读取输入中的 value,将其转化成 IntWritable 类型,最后作为输出 key
   public static class Map extends Mapper<Object, Text, IntWritable,
   IntWritable> {
       private static IntWritable data=new IntWritable();
       public void map (Object key, Text value, Context context) throws
       IOException, InterruptedException{
```

```
String text=value.toString();
        data.set(Integer.parseInt(text));
        context.write(data, new IntWritable(1));
//reduce 函数将 map 输入的 key 复制到输出的 value 上,然后根据输入的 value-list 中元素
 的个数决定 key 的输出次数,定义一个全局变量 line_num 来代表 key 的位次
public static class Reduce extends Reducer<IntWritable, IntWritable,
IntWritable, IntWritable> {
    private static IntWritable line_num=new IntWritable(1);
    public void reduce (IntWritable key, Iterable < IntWritable > values,
    Context context) throws IOException, InterruptedException {
        for(IntWritable val : values){
           context.write(line_num, key);
           line_num=new IntWritable(line_num.get()+1);
//自定义 Partition 函数,此函数根据输入数据的最大值和 MapReduce 框架中 Partition 的数
 量获取将输入数据按照大小分块的边界,然后根据输入数值和边界的关系返回对应的
  Partiton ID
public static class Partition extends Partitioner < IntWritable,
IntWritable> {
    public int getPartition(IntWritable key, IntWritable value, int num
    Partition) {
        int Maxnumber=65223;//int型的最大数值
        int bound=Maxnumber/num_Partition+1;
        int keynumber=key.get();
        for(int i=0; i<num Partition; i++){</pre>
           if(keynumber<br/>bound * (i+1) && keynumber>=bound * i){
               return i;
        return-1;
public static void main(String[] args) throws Exception{
    //TODO Auto-generated method stub
    Configuration conf=new Configuration();
    conf.set("fs.default.name", "hdfs://localhost:9000");
```

#### 3. 对给定的表格进行信息挖掘

下面给出一个 child-parent 的表格,要求挖掘其中的父子辈关系,给出祖孙辈关系的表格。

输入文件内容如下:

```
child
              parent
Steven
               Lucy
               Jack
Steven
Jone
               Lucy
               Jack
Jone
Lucy
              Mary
               Frank
Lucy
Jack
              Alice
Jack
               Jesse
David
              Alice
David
               Jesse
Philip
               David
              Alma
Philip
Mark
               David
Mark
               Alma
```

输出文件内容如下:

```
grandchild
                 grandparent
                 Alice
Steven
Steven
                 Jesse
Jone
                 Alice
Jone
                 Jesse
Steven
                 Mary
Steven
                 Frank
Jone
                 Mary
                 Frank
Jone
Philip
                 Alice
Philip
                 Jesse
Mark
                 Alice
Mark
                 Jesse
```

#### 实现上述操作的 Java 代码如下:

```
package com.simple data mining;
import java.io.IOException;
import java.util.*;
import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.Path;
import org.apache.hadoop.io.IntWritable;
import org.apache.hadoop.io.Text;
import org.apache.hadoop.mapreduce.Job;
import org.apache.hadoop.mapreduce.Mapper;
import org.apache.hadoop.mapreduce.Reducer;
import org.apache.hadoop.mapreduce.lib.input.FileInputFormat;
import org.apache.hadoop.mapreduce.lib.output.FileOutputFormat;
import org.apache.hadoop.util.GenericOptionsParser;
public class simple_data_mining {
   public static int time=0;
    /**
     * @param args
    * 输入一个 child-parent 的表格
    * 输出一个体现 grandchild-grandparent 关系的表格
   //Map将输入文件按照空格分隔成 child 和 parent,然后正序输出一次作为右表,反序输出一
     次作为左表,需要注意的是在输出的 value 中必须加上左右表区别标志
   public static class Map extends Mapper<Object, Text, Text> {
       public void map (Object key, Text value, Context context) throws
       IOException,InterruptedException{
```

```
String child name=new String();
        String parent_name=new String();
        String relation type=new String();
        String line=value.toString();
        int i=0;
        while(line.charAt(i) != ' '){
            i++;
        }
        String[] values= {line.substring(0,i),line.substring(i+1)};
        if (values[0].compareTo("child") != 0) {
            child name=values[0];
            parent name=values[1];
                                    //左右表区分标志
            relation_type="1";
            context.write(new Text(values[1]), new
            Text(relation_type+"+"+child_name+"+"+parent_name));
            //左表
            relation_type="2";
            context.write(new Text(values[0]), new
            Text(relation_type+"+"+child_name+"+"+parent_name));
            //右表
public static class Reduce extends Reducer<Text, Text, Text> {
     public void reduce (Text key, Iterable < Text > values, Context context) throws
     IOException, InterruptedException{
                     //输出表头
    if(time==0){
        context.write(new Text("grand_child"), new
        Text("grand_parent"));
        time++;
    }
    int grand_child_num=0;
    String grand_child[]=new String[10];
    int grand_parent_num=0;
    String grand parent[] = new String[10];
    Iterator ite=values.iterator();
    while(ite.hasNext()){
        String record=ite.next().toString();
        int len=record.length();
        int i=2;
        if(len==0) continue;
        char relation_type=record.charAt(0);
        String child_name=new String();
```

```
String parent_name=new String();
        //获取 value-list 中 value 的 child
        while(record.charAt(i) != '+'){
            child name=child name+record.charAt(i);
            i++;
        }
        i = i + 1;
        //获取 value-list 中 value 的 parent
        while(i<len){
            parent_name=parent_name+record.charAt(i);
            i++;
        }
        //左表,取出 child 放入 grand_child
        if(relation_type=='1'){
            grand_child[grand_child_num] = child_name;
            grand_child_num++;
        else{//右表,取出 parent 放入 grand_parent
            grand_parent[grand_parent_num]=parent_name;
            grand parent num++;
        }
    if(grand_parent_num != 0 && grand_child_num != 0) {
        for(int m= 0;m< grand_child_num;m++){</pre>
            for (int n=0;n<grand_parent_num;n++) {</pre>
                   context.write(new Text(grand_child[m]), new
                   Text(grand parent[n]));
                   //输出结果
public static void main(String[] args) throws Exception{
    //TODO Auto-generated method stub
    Configuration conf=new Configuration();
    conf.set("fs.default.name", "hdfs://localhost:9000");
    String[] otherArgs=new String[]{"input","output"}; /* 直接设置输入参数*/
    if(otherArgs.length != 2) {
        System.err.println("Usage: wordcount<in><out>");
        System.exit(2);
```

```
Job job=Job.getInstance(conf, "Single table join");
job.setJarByClass(simple_data_mining.class);
job.setMapperClass(Map.class);
job.setReducerClass(Reduce.class);
job.setOutputKeyClass(Text.class);
job.setOutputValueClass(Text.class);
FileInputFormat.addInputPath(job, new Path(otherArgs[0]));
FileOutputFormat.setOutputPath(job, new Path(otherArgs[1]));
System.exit(job.waitForCompletion(true) ? 0 : 1);
}
```

# 附录 B

# Linux 系统中的 MySQL 安装及常用操作

MySQL 是一个关系数据库管理系统,由瑞典 MySQL AB公司开发,目前属于 Oracle 旗下的产品。MySQL 是最流行的关系数据库管理系统,在 Web 应用方面,MySQL 是最好的关系数据库管理系统(Relational Database Management System, RDBMS)应用软件之一。

# B.1 安装 MySQL

#### 1. 执行安装命令

在安装 MySQL 之前,需要更新一下软件源以获得最新版本,命令如下:

\$sudo apt -get update

然后执行如下命令安装 MySQL:

\$sudo apt -get install mysql-server

上述命令会安装以下包。

- (1) apparmor<sub>o</sub>
- (2) mysql-client-5.7.
- (3) mysql-common<sub>o</sub>
- (4) mysql-server.
- (5) mysql-server-5.7.
- (6) mysql-server-core-5.7.

因此无须再安装 mysql-client 等。安装过程会提示设置 MySQL 数据库 root 用户的密码,本书统一设置密码为 hadoop,设置完成后等待自动安装即可。

#### 2. 启动 MySQL 服务

默认情况下,安装完成就会自动启动 MySQL。可以手动关闭 MySQL 服务,然后再次启动 MySQL 服务,命令如下:

\$service mysql stop

\$service mysql start

可以执行如下命令来确认是否启动成功:

```
$sudo netstat - tap | grep mysql
```

如图 B-1 所示,如果 MySQL 节点处于 LISTEN 状态,则表示启动成功。

```
dblab@ubuntu:~$ sudo netstat -tap | grep mysql
tcp 0 0 localhost:mysql *:* LISTEN
6359/mysqld
```

图 B-1 截图

#### 3. 进入 MySQL Shell 界面

执行如下命令进入 MySQL Shell 界面:

```
$mysql -u root -p
```

该命令执行以后,系统会提示输入 MySQL 数据库的 root 用户的密码,本书把密码统一设置为 hadoop;然后就进入了 mysql>命令提示符状态,如图 B-2 所示。

```
dblab@ubuntu:~$ mysql -u root -p
Enter password:
Welcome to the MySQL monitor. Commands end with ; or \g.
Your MySQL connection id is 4
Server version: 5.7.15-0ubuntu0.16.04.1 (Ubuntu)

Copyright (c) 2000, 2016, Oracle and/or its affiliates. All rights reserved.

Oracle is a registered trademark of Oracle Corporation and/or its affiliates. Other names may be trademarks of their respective owners.

Type 'help;' or '\h' for help. Type '\c' to clear the current input statement.

mysql> ■
```

图 B-2 命令提示符

在 mysql>命令提示符之后,就可以输入各种 SQL 语句,对 MySQL 数据库进行操作。

#### 4. 解决利用 Sqoop 导入 MySQL 出现的中文乱码问题

当使用 Sqoop 工具向 MySQL 数据库导入数据时,可能会出现中文乱码问题,原因是 character\_set\_server 默认设置是 latin1,不是中文编码。要查询 MySQL 数据库当前的字符编码格式,可以使用如下命令:

```
mysql> show variables like'char%';
```

执行该命令以后,会出现类似图 B-3 所示的信息。可以单个设置修改编码方式,比如,使用如下命令:

```
mysql>set character_set_server=utf8;
```

但是,通过这种方式设置字符编码格式,重启 MySQL 服务以后就会失效。因此,建议

```
ysql> show variables like "char%";
Variable_name
character set client
                            utf8
character_set_connection |
                            utf8
character_set_database
                            utf8
character_set_filesystem |
                            binary
character_set_results
                            utf8
 character_set_server
                            latin1⊲
 character_set_system
                            utf8
                            /usr/share/mysql/charsets/
 character_sets_dir
rows in set (0.00 sec)
```

图 B-3 执行结果

按照如下方式修改编码格式。

#### 1) 修改配置文件

在 Linux 系统中新打开一个终端,使用 vim 编辑器编辑/etc/mysql/mysql.conf.d/mysql.cnf 文件,命令如下:

```
$vim /etc/mysql/mysql.conf.d/mysql.cnf
```

**注意**:上面的命令是在 Linux Shell 命令提示符下执行的,不是在 mysql>命令提示符下执行,一定要注意区分。打开 mysql. cnf 文件以后,请在[mysqld]下面添加一行 character \_set\_server=utf8,如图 B-4 所示。

图 B-4 增加一行代码

#### 2) 重启 MySQL 服务

在 Linux 终端的 Shell 命令提示符(不是 mysql>命令提示符)下执行如下命令重启 MySQL 服务:

\$service mysql restart

#### 3) 登录 MySQL 查看当前编码格式

重启 MySQL 服务以后,再次使用如下命令查询 MySQL 数据库当前的字符编码格式:

mysql>show variables like'char%';

执行该命令以后,会出现类似如图 B-5 所示信息。

```
mysql> show variables like "char%";
                            Value
 character_set_client
                            utf8
 character_set_connection |
                            utf8
 character_set_database
                            utf8
 character_set_filesystem
                            binary
 character_set_results
                            utf8
 character_set_server
                            utf8
 character_set_system
                            utf8
 character_sets_dir
                            /usr/share/mysql/charsets/
 rows in set (0.00 sec)
```

图 B-5 执行结果

从图 B-5 中可以看出,字符编码格式已经修改为 utf8。

## B.2 MySQL 常用操作

#### 1. 显示数据库

可以在 mysql>命令提示符下输入如下命令显示数据库:

```
mysql> show databases;
```

注意: 每条命令后面都需要跟上英文的分号";"。

MySQL 安装完后,就会包含两个数据库,即 mysql 和 test。数据库 mysql 非常重要,它 里面有 MySQL 的系统信息,我们修改密码和新增用户,实际上就是用这个库中的相关表进 行操作。

#### 2. 显示数据库中的表

对每个数据库进行操作之前,需要使用 use 命令打开该数据库:

```
mysql>use mysql;
```

然后可以使用如下命令来显示数据库中的表:

mysql>show tables;

#### 3. 显示数据表的结构

显示数据表的结构可以采用如下格式的命令:

describe 表名;

#### 4. 查询表中的记录

查询表中的记录可以采用如下格式的命令:

select \* from 表名;

例如,显示数据库 mysql 中的 user 表中的记录,可以使用如下命令:

```
mysql>select * from user;
```

#### 5. 创建数据库

创建数据库的命令格式如下:

create database 库名;

例如,创建一个名字为 aaa 的数据库,命令如下:

mysql>create database aaa;

#### 6. 创建表

创建一个新表时,可以采用如下格式的命令:

use 库名;

create table 表名 (字段设定列表);

例如,在刚刚创建的数据库 aaa 中建立表 person,表中有 id(序号,自动增长)、xm(姓名)、xb(性别)和 csny(出身年月)4个字段,命令如下:

mysql>use aaa;

mysql>create table person (id int(3) auto\_incrementnot null primary key, xm varchar(10),xb
varchar(2),csny date);

可以用 describe 命令查看建立的 person 表的结构,命令如下:

mysql>describe person;

执行完 describe 命令以后,会出现如图 B-6 所示信息。

```
mysql> describe person;
                       | Null | Key | Default
  Field | Type
 id
          int(3)
                         NO
                                PRI
                                      NULL
                                                 auto_increment
          varchar(10)
                        YES
                                      NULL
  ΧM
          varchar(2)
  хb
                         YES
                                      NULL
                        YES
  csny
          date
                                      NULL
 rows in set (0.00 sec)
```

图 B-6 执行结果

#### 7. 增加记录

例如,可以执行如下命令向 person 表中增加几条相关记录:

```
mysql>insert into person values (null,'张三','男','1997-01-02');
mysql>insert into person values (null,'李四','女','1996-12-02');
```

因为在创建表时设置了 id 自增,因此无须插入 id 字段,用 null 代替即可。可用 select 命令查询 person 表的记录来验证插入记录是否成功:

```
mysql>select * from person;
```

执行该命令后会得到如图 B-7 所示的结果。

图 B-7 执行结果

#### 8. 修改记录

例如,将张三的出生年月改为1971-01-10,命令如下:

```
mysql>update person set csny='1971-01-10' where xm='张三';
```

#### 9. 删除记录

例如,可以执行如下命令删除张三的记录:

```
mysql>delete from person where xm='张三';
```

#### 10. 删除数据库和表

删除数据库和表的命令格式如下:

```
drop database 库名;
drop table 表名;
```

#### 11. 查看 MySQL 版本

可以使用如下命令查看 MySQL 的版本信息:

mysql> show variables like 'version';

或者也可以使用如下命令查看 MySQL 版本信息:

mysql> select version();

# 参考文献

- [1] 林子雨. 大数据技术原理与应用[M]. 2版. 北京:人民邮电出版社,2017.
- [2] 陆嘉恒. Hadoop 实战[M]. 2版. 北京: 机械工业出版社,2012.
- [3] Tom White. Hadoop 权威指南(中文版). 周傲英等,译. 北京: 清华大学出版社,2010.
- [4] 维克托·迈尔-舍恩伯格,肯尼思·库克耶.大数据时代[M].生活、工作与思维的大变革.盛杨燕等,译.杭州.浙江人民出版社,2013.
- [5] 王鹏. 云计算的关键技术与应用实例[M]. 北京: 人民邮电出版社,2010.
- [6] 黄宜华. 深入理解大数据——大数据处理与编程实践[M]. 北京: 机械工业出版社,2014.
- [7] 蔡斌,陈湘萍. Hadoop 技术内幕——深入解析 Hadoop Common 和 HDFS 架构设计与实现原理[M]. 北京: 机械工业出版社,2013.
- [8] HBase. http://HBASE. apache. org.
- [9] Nick Dimiduk, Amandeep Khurana. HBase 实战[M]. 谢磊,译. 北京: 人民邮电出版社,2013.
- [10] 罗燕新. 基于 HBase 的列存储压缩算法的研究与实现[M]. 广州: 华南理工大学出版社,2011.
- [11] 颜开. NoSQL 数据库笔谈. http://kecheng. baidu. com/view/c5f3420dba1aa8114431d92d. html.
- [12] 林子雨,赖永炫,林琛,等.云数据库研究[J].软件学报.2012,23(5):1148-1166.
- [13] Jeffrey Dean, Sanjay Ghemawat. MapReduce: Simplified Data Processing on Large Clusters. In proceedings of the 6th Symposium on Operating System Design and Implementation (OSDI 2004), San Francisco, California, USA, December 6-8, 2004[C]. California: USENIX Association, 2004.
- [14] Apache Hadoop Project. http://hadoop. apache. org.
- [15] 阿里云 RDS. http://www.aliyun.com/product/rds.
- [16] Apache Hadoop. Hadoop Commands Guide. http://hadoop. apache. org/docs/r1. 0. 4/commands\_manual. html.
- [17] Apache Hadoop. HDFS User Guide. http://hadoop. apache. org/docs/r1. 0. 4/hdfs\_user\_guide. html.
- [18] Zookeeper. http://www.ibm.com/developerworks/cn/opensource/os-cn-zookeeper.
- [19] Rajiv Ranjan. Streaming Big Data Processing in Datacenter Clouds[J]. IEEE Cloud Computing, 2014, 1(1): 78-83.
- [20] Eric Redmond. 七天七数据库[M]. 王海鹏等,译. 北京: 人民邮电出版社,2013.
- [21] 陆嘉恒. 大数据挑战与 NoSQL 数据库技术[M]. 北京. 电子工业出版社,2013.
- [22] Tom White. Hadoop: The Definitive Guide. 3rd Edition. CA: O'Reilly, 2012.
- [23] 范凯. NoSQL 数据库综述. 程序员,2010 年第 6 期.
- [24] Katarina Grolinger, Wilson A Higashino, Abhinav Tiwaril, et al. Data management in cloud environments: NoSQL and NewSQL data stores [J]. Journal of Cloud Computing: Advances, Systems and Applications, 2013, 2(1):22.
- [25] 于俊,向海,代其锋,等. Spark 核心技术与高级应用[M]. 北京: 机械工业出版社,2016.
- [26] 王道远. Spark 快速大数据分析[M]. 北京: 人民邮电出版社,2015.
- [27] Nathan Yau. 鲜活的数据——数据可视化指南[M]. 向怡宁,译. 北京: 人民邮电出版社,2015.
- [28] 王珊,萨师煊.数据库系统概论[M].5 版.北京:高等教育出版社,2014.
- [29] 申德荣,于戈,王习特,等. 支持大数据管理的 NoSQL 系统研究综述[J]. 软件学报,2013,08: 1786-1803.

- [30] 朝乐门. 数据科学[M]. 北京: 清华大学出版社, 2016.
- [31] 大数据魔镜. http://www.moojing.com.
- [32] Spark. http://spark. apache. org/.
- [33] Redis. https://redis. io/.
- [34] MongoDB. https://www.mongodb.com/.
- [35] Hive. http://hive. apache. org/.
- [36] ECharts. http://echarts. baidu. com/.
- [37] Douglas Crockford. JavaScript 语言精粹[M]. 赵泽欣,鄢薛鹍,译. 北京: 电子工业出版社,2015.
- [38] 鸟哥. 鸟哥的 Linux 私房菜基础学习篇[M]. 3 版. 北京: 人民邮电出版社,2016.
- [39] 王飞飞,崔洋,贺亚茹. MySQL 数据库应用从入门到精通[M]. 2 版. 北京:中国铁道出版社,2016.
- [40] Edward Capriolo, Dean Wampler, Jason Rutberglen. Hive 编程指南[M]. 曹坤,译. 北京: 人民邮电出版社,2016.
- [41] Cay S. Horstmann. 快学 Scala[M]. 高宇翔,译. 北京: 电子工业出版社,2016.